

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Stjepan Lojen**

Zagreb, 2015.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

Mentori:

Prof. dr. sc. Predrag Ćosić, dipl. ing.

Student:

Stjepan Lojen

Zagreb, 2015.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem svim profesorima s preddiplomskog studija smjera Industrijsko inženjerstvo i menadžment na njihovoj stručnosti, razumijevanju i savjetima tijekom studija.

Posebno bih se zahvalio mentoru prof. dr. sc. Predragu Ćosiću na velikom razumijevanju, strpljenju, savjetima te posvećenom vremenu i trudu prilikom izrade završnog rada.

Veliko hvala mojim roditeljima na velikoj podršci, strpljenju i motivaciji za vrijeme trajanja studija.

Stjepan Lojen



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje
Datum 24-02-2015 Prilog
Klasa: 602-04/15-613
Ur.broj: 15-1703-15-34

## ZAVRŠNI ZADATAK

Student: **STJEPAN LOJEN**

Mat. br.: **0035186276**

Naslov rada na hrvatskom jeziku: **Podrška odlučivanju kod odabira primarnog procesa u projektiranju tehnološkog procesa**

Naslov rada na engleskom jeziku: **Decision Support in Primary Process Selection During Process Planning**

Opis zadatka:

U projektiranju tehnoloških procesa bitan značaj u odabiru primarnog procesa imaju tehnološki, organizacijski i ekonomski kriteriji. Temeljem odabira primarnog procesa, može se razraditi više varijanti tehnološkog procesa. Kako kriteriji odabira nisu uvijek kvantitativni, teško ih je obuhvatiti jedinstvenim algoritmom ili nisu dovoljno generalizirajući te se u praksi najčešće pribjegava iskustvenim rješenjima.


Koristeći literaturu, temeljem odabranog tehnološkog procesa, objasniti pojam primarnog procesa, razraditi kriterije, ponderirati i hijerarhijski ih posložiti kako bi se koristila AHP metoda pri odlučivanju o odabiru traženog primarnog procesa. Opisati sustav za potporu i odlučivanje AHP metodu (analitičko hijerarhijski proces) u softverskoj aplikaciji "Expert Choice". Primijeniti aplikaciju pri odabiru primarnog procesa za odabrani izradak.

Zadatak zadan:  
25. studenog 2014.


Rok predaje rada:  
**1. rok:** 26. veljače 2015.  
**2. rok:** 17. rujna 2015.

Predviđeni datumi obrane:  
**1. rok:** 2., 3., i 4. ožujka 2015.  
**2. rok:** 21., 22., i 23. rujna 2015.

Zadatak zadao:

  
Prof.dr.sc. Predrag Čosić

Predsjednik Povjerenstva:

  
Prof. dr. sc. Zoran Kunica

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TEHNIČKE DOKUMENTACIJE .....	VI
POPIS KRATICA .....	VII
SAŽETAK.....	VIII
SUMMARY .....	IX
1. UVOD.....	1
2. ZNAČAJ ODABIRA PRIMARNOG PROCESA NA TRAJANJE CIKLUSA I TROŠKOVE PROIZVODNJE.....	2
2.1. Podjela i vrste primarnih procesa.....	2
2.2. Odabir prema ASM i Haleviju .....	3
2.2.1. Prikaz reprezentanata grupe izradaka .....	6
3. PRIKAZ I ANALIZA KRITERIJA ZA ODABIR PRIMARNOG PROCESA.....	7
3.1. Značaj kriterija .....	7
4. SUSTAVI ZA POTPORU ODLUČIVANJA (DSS).....	9
4.1. Prikaz povijesti sustava za potporu odlučivanja .....	9
4.2. Vrste DSS-a.....	11
4.2.1. DSS zasnovan na modelu.....	12
4.2.2. DSS zasnovan na podacima .....	12
4.2.3. DSS zasnovan na komunikacijama .....	13
4.2.4. DSS zasnovan na dokumentima.....	13
4.2.5. DSS zasnovan na znanju .....	13
4.2.6. DSS zasnovan na WEB-u .....	14
5. ANALITIČKO HIJERARHIJSKI PROCES (AHP METODA) .....	15
5.1. AHP metoda.....	16
5.2. Provedba AHP metode.....	17
5.3. Konzistentnost.....	19
5.4. Saatyeva skala .....	20
5.5. Prednosti i nedostaci AHP .....	21
6. EXPERT CHOICE SOFTVERSKA APLIKACIJA .....	24

6.1. Razvoj programa Expert Choice .....	24
6.2. Značajke Expert Choice-a .....	24
6.3. Praktična primjena Expert Choice-a .....	25
6.4. Struktura Expert Choice modela .....	26
6.4.1. Model View .....	26
6.4.2. Izrada novog modela .....	27
6.4.3. Donošenje parnih prosudbi .....	29
6.4.3.1. Numerička komparacija .....	29
6.4.3.2. Grafička komparacija .....	30
6.4.3.3. Verbalna komparacija .....	30
6.4.3.4. Usporedba kriterija i alternativa verbalnom komparacijom .....	31
6.4.3.5. Provođenje osjetljivosti pomoću Expert Choice-a .....	34
7. ODABIR PRIMARNOG PROCESA POMOĆU EXPERT CHOICE .....	39
7.1. Proizvod i njegove značajke .....	39
7.2. Hijerarhijska struktura za odabir primarnog procesa .....	40
7.2.1. Ponderiranje kriterija za odabir primarnog procesa .....	41
7.2.2. Prikaz prioriteta kriterija i podkriterija u Tree View oknu .....	44
7.3. Odabir najbolje alternative .....	45
7.3.1. Ponderiranje najbolje alternativa .....	45
7.4. Rezultati AHP metode u Expert Choice-u .....	52
7.4.1. Konzistentnost .....	53
7.4.2. Graf osjetljivosti .....	53
7.5. Konačni odabir .....	55
8. MOGUĆNOST PRIMJENE AHP METODE U INDUSTRIJI .....	57
ZAKLJUČAK .....	58
LITERATURA .....	59
PRILOZI .....	61

## POPIS SLIKA

Slika 2.1	Podjela i vrste primarnih procesa [2] .....	3
Slika 2.2	Odabir prema ASM i Haleviju [3].....	5
Slika 4.1	Komponente DSS-a zasnovanog na WEB-u [9] .....	14
Slika 5.1	Primjer hijerarhijske strukture [16] .....	18
Slika 5.2.	Primjer konzistentnosti [17] .....	19
Slika 6.1	Model View prozor .....	26
Slika 6.2	Unos kriterija.....	27
Slika 6.3	Unos alternativa.....	28
Slika 6.4	Unos informacija .....	28
Slika 6.5	Numerička skala .....	29
Slika 6.6	Grafička skala.....	30
Slika 6.7	Verbalna skala .....	31
Slika 6.8	Odabir komparacije kriterija .....	31
Slika 6.9	Rezultati parne komparacije kriterija .....	32
Slika 6.10	Odabir komparacije alternativa .....	32
Slika 6.11	Rezultati parne komparacije alternativa .....	33
Slika 6.12	Sinteza rezultata .....	33
Slika 6.13	Gradient prikaz .....	35
Slika 6.14	Dynamic prikaz - početni problem.....	35
Slika 6.15	Dynamic prikaz - izmijenjeni problem.....	36
Slika 6.16	Dynamic - Components prikaz.....	36
Slika 6.17	Head to Head grafikon .....	37
Slika 6.18	Performance grafikon .....	38
Slika 6.19	2D grafikon.....	38
Slika 7.1	Glavina .....	39
Slika 7.2	Hijerarhijska struktura odabira primarnog procesa .....	40
Slika 7.3	Model View prikaz odabira primarnog procesa za izradak Glavina .....	41
Slika 7.4	Procjena i sinteza rezultata podkriterija u odnosu na podkriterij Funkcionalna svojstva.....	42

Slika 7.5	Procjena i sinteza rezultata podkriterija u odnosu na podkriterij Geometrijske značajke .....	42
Slika 7.6	Procjena i sinteza rezultata podkriterija u odnosu na kriterij Sukladnost materijala i tehnologije .....	42
Slika 7.7	Procjena i sinteza rezultata podkriterija u odnosu na kriterij Troškovi.....	43
Slika 7.8	Procjena i sinteza rezultata podkriterija u odnosu na kriterij Proizvodnja.....	43
Slika 7.9	Procjena i sinteza rezultata kriterija u odnosu na Cilj: Odabir primarnog procesa .....	44
Slika 7.10	Prikaz prioriteta kriterija i podkriterija.....	44
Slika 7.11	Rezultati procjene alternativa u odnosu na podkriterij Funkcionalna svojstva....	46
Slika 7.12	Rezultati procjene alternativa u odnosu na podkriterij Hrapavost površine .....	46
Slika 7.13	Rezultati procjene alternativa u odnosu na podkriterij Preciznost .....	46
Slika 7.14	Rezultati procjene alternativa u odnosu na podkriterij Gotovost .....	47
Slika 7.15	Rezultati procjene alternativa u odnosu na podkriterij Troškovi primarnog procesa.....	47
Slika 7.16	Rezultati procjene alternativa u odnosu na podkriterij Troškovi završne obrade	48
Slika 7.17	Rezultati procjene alternativa u odnosu na podkriterij Proizvodnost.....	48
Slika 7.18	Rezultati procjene alternativa u odnosu na podkriterij Minimalna količina .....	48
Slika 7.19	Rezultati procjene alternativa u odnosu na podkriterij Vrijeme uhodavanja proizvodnje .....	49
Slika 7.20	Rezultati procjene alternativa u odnosu na podkriterij Vještina radnika .....	49
Slika 7.21	Rezultati procjene alternativa u odnosu na podkriterij Ukupno vrijeme izrade...	50
Slika 7.22	Rezultati procjene alternativa u odnosu na podkriterij Troškovi primarnog procesa.....	50
Slika 7.23	Rezultati procjene alternativa u odnosu na podkriterij Troškovi završne obrade	51
Slika 7.24	Rezultati procjene alternativa u odnosu na podkriterij Minimalna količina .....	51
Slika 7.25	Rezultati procjene alternativa u odnosu na podkriterij Ukupno vrijeme izrade...	51
Slika 7.26	Model View prikaz rezultata za veličinu serije 50 000 komada .....	52
Slika 7.27	Model View prikaz rezultata za veličinu serije 2 000 komada .....	52
Slika 7.28	Nekonzistentnost odabira primarnog procesa .....	53
Slika 7.29	Dijagram osjetljivosti Performance .....	54
Slika 7.30	Dijagram osjetljivosti Dynamic.....	55



**POPIS TABLICA**

Tablica 2.1 Prikaz prema složenosti izratka Halevi [4].....	6
Tablica 2.2 Prikaz prema složenosti izratka ASM [4].....	6
Tablica 3.1 Prikaz kriterija za odabir primarnog procesa .....	7
Tablica 5.1 Vrijednost RI slučajnih indeksa (Saaty, 1980.) [18] .....	20
Tablica 5.2 Saatyeva skala [10].....	21

## POPIS TEHNIČKE DOKUMENTACIJE

BROJ CRTEŽA	Naziv iz sastavnice
1000-10-10	Glavina

**POPIS KRATICA**

DSS	- Decision Support System - Sustav za potporu odlučivanju
GDSS	- Group Decision Support System - Grupni sustavi za potporu odlučivanju
AHP	- Analytic Hierarchy Process - Analitičko hijerarhijski proces
EC	- Expert Choice
BAM	- Business Activity Monitoring
BPM	- Business Process Management
OLAP	- On Line Analytical Processing - Online analitička obrada
EIS	- Executive Information System - Informacijski sustavi za izvršne rukovoditelje
CI	- Consistency Index - Indeks konzistentnosti
RI	- Random Index - Slučajni indeks
CR	- Consistency Range - Stupanj konzistentnosti
OOČ	- Obrada odvajanjem čestica

## SAŽETAK

U ovome radu razrađen je problem odlučivanja kod odabira primarnog procesa u projektiranju tehnološkog procesa, kao i kratki uvod u značaj i odabir primarnog procesa. Okosnica ovog rada je definiranje kriterija po kojima će se odabrati isti.

Dan je opis sustava za potporu odlučivanju kao suvremenog alata pri donošenju poslovnih, strateških i organizacijskih odluka, vrste sustava za potporu odlučivanju te njihov razvoj.

Nadalje, predstavljena je AHP (Analitički hijerarhijski proces) metoda, jedna od najpoznatijih metoda stručne analize scenarija i donošenja odluka konzistentnim ocjenjivanjem hijerarhija koje se sastoje od ciljeva, kriterija, scenarija i alternativa. Također, dan je kratak opis provedbe AHP metode te najznačajnije prednosti i mane u njoj provedbi.

Praktični rad proveden je u Expert Choice-u, efikasnom softverskom alatu za rješavanje problema višekriterijskog odlučivanja na razini organizacije, zasnovanog na maloprije spomenutoj AHP metodi. Nakon kratkog teorijskog opisa razvoja, značajki, praktične primjene i strukture Expert Choice-a, provedena je primjena softvera na realnom problemu - odabiru primarnog procesa za odabrani izradak.

Ključne riječi: Odabir primarnog procesa, Sustavi za potporu odlučivanju, Analitički hijerarhijski proces, Expert Choice

## **SUMMARY**

This paper elaborates the problem of decision making in the selection of primary process of designing technological process. The base of this work is to define criteria by which the process will be chosen.

A description is given of decision support systems as a modern tool for making business, strategic and organizational decisions, types of decision support systems and their development.

Furthermore, the AHP (Analytical Hierarchy Process) method, one of the most popular methods of professional scenario analysis and decision-making consistent evaluation hierarchy consisting of the objectives, criteria, scenarios and alternatives, is presented. Also, a brief description of the implementation of the AHP method and the most important advantages and disadvantages in its implementation is given.

Practical work was carried out in the Expert Choice, efficient software tool for problem solving multiple criteria decision making at the level of the organization, based on the earlier mentioned AHP method. After a brief theoretical description of the development, characteristics, practical application and structure of Expert Choice, the application software is implemented on the real problem - the selection of the primary process for the selected workpiece.

Key words: Selection of primary process, Decision Support Systems, Analytical Hierarchy Process, Expert Choice

## 1. UVOD

Projektiranje tehnološkog procesa je skup tehničkih znanja i praktičnih iskustava usmjerenih na definiranje slijeda postupaka i režima procesa obrade s ciljem pretvaranja priprema u gotov proizvod. Projektiranje tehnološkog procesa sastoji se od nekoliko faza:

- Odabir primarnog procesa
- Odabir tipa i redoslijeda operacija
- Način pozicioniranja i stezanja
- Odabir stroja i alata
- Greške obrade
- Proračun vremena i troška izrade

Jedna od važnijih faza, ako ne i najvažnija, u projektiranju tehnološkog procesa je odabir primarnog procesa, što se i obrađuje u ovome radu. Ova faza u znatnoj mjeri utječe na konačni proizvod, naročito njegovu cijenu. Cilj je postići krajnji oblik u što manje operacija. Idealno bi bilo odabrati takav primarni proces koji bi dao proizvod jednak, željenom, krajnjem proizvodu, no u praksi je čest slučaj da to nije izvedivo. Pa se u takvim slučajevima odabire optimalni proces koji će rezultirati izratkom koji je što sličniji krajnjem proizvodu, kako bi se s minimalnom obradom dobio krajnji izgled što će skratiti, a time i pojeftiniti obradu, tzv. „*near net shape*“. Pri tome su bitna i njegova mehanička svojstva. Osim na vrijeme izrade, ovaj izbor utječe i na odabir tipa i redoslijeda operacija, te na kraju i na izbor alata i strojeva.

Najveći problem kod izbora primarnog procesa je kako odlučiti koji proces je optimalan za određeni izradak, koji su to kriteriji po kojima se to može odlučiti i kako analizirati odluku. Time će se ovaj rad baviti u nastavku.

## 2. ZNAČAJ ODABIRA PRIMARNOG PROCESA NA TRAJANJE CIKLUSA I TROŠKOVE PROIZVODNJE

Kao što je već rečeno u uvodu, cilj odabira primarnog procesa jest odabrati proizvodni postupak kojim se dobiva izradak približnog oblika i dimenzija kao i gotovi proizvod („*Near net shape*“). Time se postiže da broj operacija proizvodnog postupka bude što manji, da se dobije što kraće vrijeme izrade, kraći proizvodni ciklus te mogućnost kraćeg roka isporuke. Ujedno smanjenjem broja operacija i vremena izrade dobivaju se i manji troškovi izrade. Troškovi se ujedno smanjuju i prebacivanjem na visokoproduktivnu proizvodnju, koja je rezultat primjene visokoproduktivnih strojeva, adekvatne organizacije, kraćih pomoćnih vremena pri stezanju, prebacivanja s jedne na drugu operaciju (minimizacija broja stezanja, broja promjena strojeva, razina automatizacije pri unutarnjem transportu i sl.), gdje cijena pada s povećanjem broja proizvedenih komada, tj. amortizacija strojeva, alata te zaposlenika je veća i brža. Vrlo važno kod odabira primarnog procesa je i smanjenje otpadnog materijala, tj. u idealnom slučaju dobivanje gotovog proizvoda. [1]

### 2.1. Podjela i vrste primarnih procesa

Podjela primarnih procesa može se razvrstati u sedam osnovnih grupa procesa:

- ljevačke procese
- polimerne i kompozitne procese
- procese deformiranja (masivna tijela, limovi)
- procese obrade odvajanjem čestica
- netradicionalne procese obrade odvajanjem čestica
- sustave montaže
- i procese spajanja. [2]

Daljnje grananje prikazano je na Slici 2.1.

<b>1</b>	<b>Casting Processes</b>	<b>4</b>	<b>Machining Processes</b>
1.1	Sand Casting	4.1	Turning and Boring
1.2	Shell Moulding	4.2	Milling
1.3	Gravity Die Casting	4.3	Planing and Shaping
1.4	Pressure Die Casting	4.4	Drilling
1.5	Centrifugal Casting	4.5	Broaching
1.6	Investment Casting	4.6	Reaming
1.7	Ceramic Mould Casting	4.7	Grinding
1.8	Plaster Mould Casting	4.8	Honing
1.9	Squeeze Casting	4.9	Lapping
<b>2</b>	<b>Plastic &amp; Composite Processing</b>	<b>5</b>	<b>Nontraditional Machining (NTM) Processes</b>
2.1	Injection Moulding	5.1	Electrical Discharge Machining (EDM)
2.2	Reaction Injection Moulding	5.2	Electrochemical Machining (ECM)
2.3	Compression Moulding	5.3	Electron Beam Machining (EBM)
2.4	Transfer Moulding	5.4	Laser Beam Machining (LBM)
2.5	Vacuum Forming	5.5	Chemical Machining (CM)
2.6	Blow Moulding	5.6	Ultrasonic Machining (USM)
2.7	Rotational Moulding	5.7	Abrasive Jet Machining (AJM)
2.8	Contact Moulding		
2.9	Continuous Extrusion (Plastics)	<b>6</b>	<b>Assembly Systems</b>
<b>3</b>	<b>Forming Processes</b>	6.1	Manual Assembly
3.1	Forging	6.2	Flexible Assembly
3.2	Rolling	6.3	Dedicated Assembly
3.3	Drawing		
3.4	Cold Forming	<b>7</b>	<b>Joining Processes</b>
3.5	Cold Heading	7.1	Tungsten Inert-gas Welding (TIG)
3.6	Swaging	7.2	Metal Inert-gas Welding (MIG)
3.7	Superplastic Forming	7.3	Manual Metal Arc Welding (MMA)
3.8	Sheet-metal Shearing	7.4	Submerged Arc Welding (SAW)
3.9	Sheet-metal Forming	7.5	Electron Beam Welding (EBW)
3.10	Spinning	7.6	Laser Beam Welding (LBW)
3.11	Powder Metallurgy	7.7	Plasma Arc Welding (PAW)
3.12	Continuous Extrusion (Metals)	7.8	Resistance Welding
		7.9	Solid State Welding
		7.10	Thermit Welding (TW)
		7.11	Gas Welding (GW)
		7.12	Brazing
		7.13	Soldering
		7.14	Thermoplastic Welding
		7.15	Adhesive Bonding
		7.16	Mechanical Fastening

Slika 2.1 Podjela i vrste primarnih procesa [2]

## 2.2. Odabir prema ASM i Haleviju

Kratki opis ovih klasifikacija bio bi grupiranje oblika pogodnih za obradu istom tehnologijom. Postupci odabira po ASM-u i Haleviju imaju neke zajedničke kriterije, ali su im pristupi različiti. ASM [3] vrši početnu klasifikaciju prema geometrijskim značajkama, u sljedećim fazama daje uvid u odabir materijala, te prikaz međudjelovanja materijala i tehnoloških procesa. Halevi [3] započinje s klasifikacijom oblika, ali povezano s količinom proizvodnje. U nastavku uzima u obzir naredni tehnološki proces uz već odabran materijal.

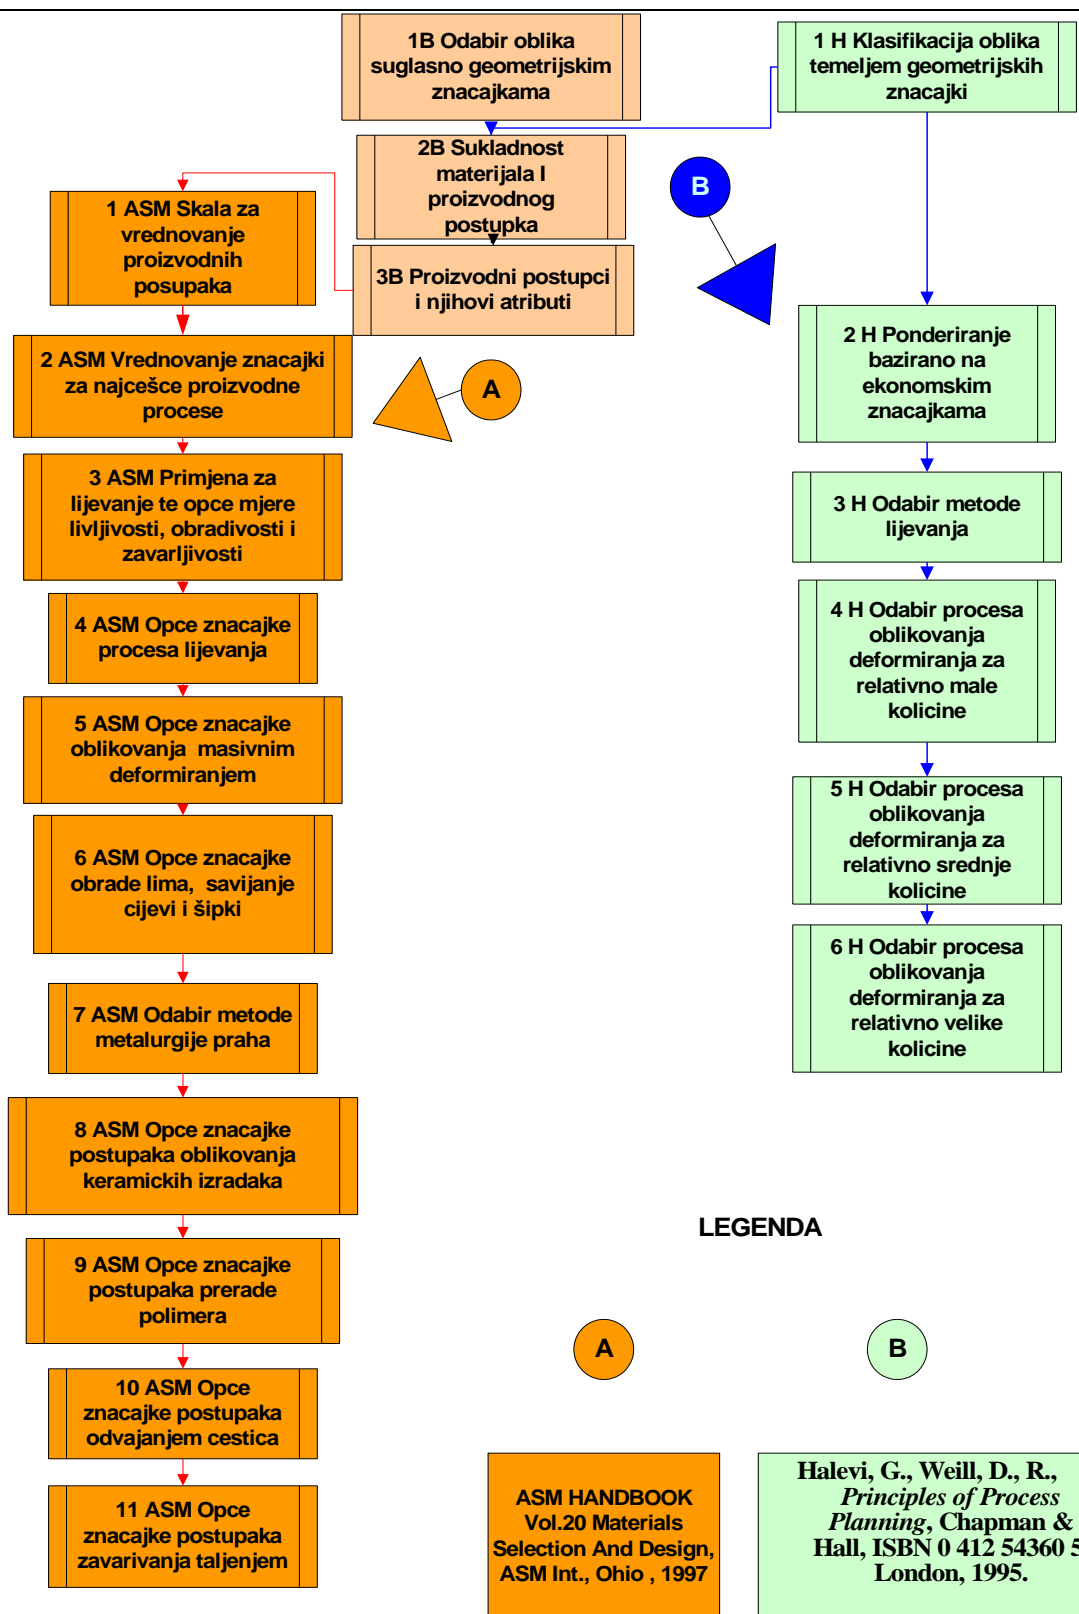


ASM je temeljitiji jer najprije provjerava oblik i materijal izratka, a tek onda bira prikladnu tehnologiju. Haleviju je uvjet za izbor tehnologije ukupna količina, ekonomski faktor.

Izbor se vrši uz upotrebu tablica koje su navedene u skraćenom pregledu na Slici 2.2. Ako se promotri usporedan postupak izbora primarnog procesa, vidljivo je da Halevijev pristup u većem dijelu razmatra ekonomske značajke. Započinje klasifikacijom oblika prema geometrijskim značajkama, ali vrlo grubo. Te nakon toga nudi samo dvije grupe tehnologija: lijevanje i deformiranje. Glavni faktor je ukupna količina.

Paralelno s tim izborom može se pratiti ASM pristup. Započinje kao i Halevi, klasifikacijom oblika ali znatno detaljnijom. Potom se ispituje sukladnost materijala i odgovarajućih proizvodnih postupaka. ASM daje mogućnost vrednovanja raznih tehnologija prikladnih za primjenu na određenom materijalu. Za razliku od Halevija navodi više od dvije tehnologije: lijevanje, deformiranje, ali i obradu lima, šipki i cijevi, metalurgiju praha, preradu polimera, obradu odvajanjem čestica i drugo. ASM nudi više od prikladnih tehnologija, ali usporedbe za odabir nisu dovoljno egzaktna. To je i nedostatak ASM-a. Kada se uđe u pojedine tehnologije, daje kvantitativne i atributivne usporedbe za odabir željene tehnologije. Tu će se nastupiti s AHP metodom kao pomoći za usporedbu različitih varijanti (alternativa).

Oba pristupa ne daju precizan odgovor na pitanje zadovoljavajućeg procesa, niti ne barataju s brojčanim ocjenama koje bi jednoznačno ukazale na najbolji proces. U oba slučaja, iskustvo i znanje tehnologa su presudni za izbor tehnologije. [3]



Slika 2.2

Odabir prema ASM i Haleviju [3]







































### 2.2.1. Prikaz reprezentanata grupe izradaka

U nastavku je prikaz reprezentanata grupe izradaka prema Haleviju (Tablica 2.1) i ASM-u (Tablica 2.2) prema složenosti. Iz tablica je vidljivo da ASM ima znatno detaljniji prikaz reprezentanata grupe izradaka.

**Tablica 2.1 Prikaz prema složenosti izratka Halevi [4]**

MONO	OTVORENI	SLOŽENI	VRLO SLOŽENI
			
			
			

**Tablica 2.2 Prikaz prema složenosti izratka ASM [4]**

	0 JEDNOLIKI PRESJEK	1 PROMJENA NA KRAJU	2 PROMJENA NA SREDINI	3 PROSTORNA KRIVINA	4 ZATVOREN JEDAN KRAJ	5 ZATVORENA OBA KRAJA	6 POPREČNI ELEMENT	7 SLOŽENI OBLIK
OKRUGLI (R)								
PRAVOKUTNI (B)								
PRESJEK OTVOREN (S) POLUZATVOREN (PPS)								
CIJEV (T)								
RAVNO (F)								
SFERNI (SF)								

### 3. PRIKAZ I ANALIZA KRITERIJA ZA ODABIR PRIMARNOG PROCESA

Definiranje kriterija predstavlja prvi korak u procesu odabira primarnog procesa. Donositelj odluke definira svoje preferencije prema kojima će iz baze podataka dostupnih proizvodnih tehnologija definirati najbolju alternativu. Pri tom se najprije postave željene specifikacije tehnologije, kao što su sukladnost materijala i tehnologije, troškovi i sl., te se filtriraju tehnologije koje ne zadovoljavaju ove specifikacije.

U daljnjem tijeku procesa razmatraju se kriteriji odabira primarnog procesa. U Tablici 3.1 je prikazan jedan scenarij definiranja kriterija i podkriterija za odabir primarnog procesa.

**Tablica 3.1**                      **Prikaz kriterija za odabir primarnog procesa**

KRITERIJI	PODKRITERIJI	
Sukladnost materijala i tehnologije	Funkcionalna svojstva	Čvrstoća
		Tvrdoća
		Žilavost
		Zamor materijala
	Masa	
	Hrapavost površine	
	Preciznost	
	Gotovost	
	Geometrijske značajke	Minimalna debljina presjeka
		Oblik izratka
Troškovi	Troškovi primarnog procesa	
	Troškovi završne obrade	
Proizvodnja	Proizvodnost	
	Minimalna količina	
	Vrijeme uhodavanja proizvodnje	
	Vještina radnika	
	Ukupno vrijeme izrade	

#### 3.1.              Značaj kriterija

Najvažniji kriterij prilikom odabira primarnog procesa svakako je *Sukladnost materijala i tehnologije*. Ako proizvodnom tehnologijom ne može se izraditi izradak odgovarajućeg materijala, tehnologija se automatski izbacuje iz analize, čime se smanjuje broj alternativa

koje se promatraju kod odabira primarnog procesa. Podkriteriji tog kriterija su funkcionalna svojstva, masa, hrapavost površine, geometrijske značajke, gotovost i preciznost (Tablica 3.1). Svaki od podkriterija može rezultirati izbacivanjem neke od tehnologija. Tako npr. opće je poznato da se osovine i vratila ne lijevaju jer se lijevanjem ne može postići željena strukturna svojstva za tražene funkcionalne značajke.

Podkriterij gotovost govori koliko se blizu može dobiti izradak koji je što sličniji krajnjem proizvodu, kako bi se s minimalnom obradom dobio krajnji izgled što će skratiti, a time i pojeftiniti obradu, tzv. „*near net shape*“.

Bitni kriteriji svakako su i troškovi. Cilj proizvodnje je ostvariti profit. Profit je definiran kao razlika cijene proizvoda i ukupnih troškova:

$$Profit = Cijena\ proizvoda - Ukupni\ troškovi$$

Iz čega proizlazi da smanjenjem ukupnih troškova raste profit, uz zadržavanjem iste cijene proizvoda. U ukupne troškove ulaze troškovi radne snage, opreme, alata, završne obrade i održavanja.

Razlika podkriterija gotovosti i troškova završne obrade je u sljedećem. Ako se tehnologijom može dobiti takav izradak koji je što više sličniji krajnjem proizvodu to će i troškovi završne obrade biti niži, odnosno što se više „udaljavamo“ od krajnjeg proizvoda to će i troškovi završne obrade biti viši. Moglo bi se reći da su obrnuto proporcionalni. Dok jedan raste, drugi pada i obrnuto.

Bitni kriteriji su i kriteriji povezani s proizvodnjom, odnosno proizvodnost, minimalna količina proizvoda za koju se isplati koristiti određena tehnologija, vrijeme uhodavanja proizvodnje, vještina radnika te ukupno vrijeme izrade. Ovi kriteriji su usko povezani s troškovima. Troškovi će biti viši sa visokokvalificiranom radnom snagom, s duljim vremenom izrade i duljim vremenom uhodavanja proizvodnje.

## 4. SUSTAVI ZA POTPORU ODLUČIVANJA (DSS)

Sedamdesetih godina prošlog stoljeća znanstvenici su počeli prepoznavati važnu ulogu računalno podržanog informacijskog sustava, koji pomažu menadžerima u njihovom donošenju odluka u rješavanju strukturiranih, podstrukturiranih i nestrukturiranih problema. Od tada, sustavi za potporu odlučivanju postaju bitan dio računalno podržanog informacijskog sustava. Razvijaju se s ciljem smanjivanja sveprisutne nesigurnosti kod donošenja poslovnih odluka. Postoji jako puno definicija DSS-a. Jedna od definicija je da je to specifičan kompjuteriziran informacijski sustav koji podupire poslovanje i poslovno odlučivanje u poduzeću. Kvalitetno izrađen DSS je interaktivan računalni sustav koji ima za cilj pomoći donositeljima odluke da prikupe informacije iz neobrađenih podataka, dokumenata i poslovnih modela da bi identificirali i riješili probleme te donijeli odluke. DSS-i su dio cjelokupnog informacijskog sustava poduzeća. DSS obrađuje postojeće podatke, dobivene iz različitih unutarnjih i vanjskih izvora da bi stvorio informacije potrebne za odlučivanje. Pomaže menadžeru pri organizaciji informacija, identifikaciji i dohvatima informacija potrebnih za donošenje odluke, te analizi i transformaciji tih informacija. Osnovna namjena takvih sustava je rukovodstvu tvrtke pružiti informacije za donošenje poslovnih odluka u realnom vremenu.

DSS je jedan od najsloženijih informacijskih sustava. Ovaj sustav služi za potporu odlučivanju kod slabostukturiranih i nestrukturiranih problema, a također su popularni u donošenju rutinskih problema. Svaki ovakav sustav mora biti dovoljno jednostavan i orijentiran ka korisniku, kako bi bio pristupačniji, te mora biti fleksibilan kako bi prihvatio promjene u načinu odlučivanja ili zadanom problemu te u skladu s tim kvalitetno odgovoriti na tu promjenu. [5]

### 4.1. Prikaz povijesti sustava za potporu odlučivanja

Prvi oblici sustava za potporu odlučivanju pojavili su se 60-tih godina prošlog stoljeća. Ne postoji jednoznačna povijest razvoja sustava, a pojedini autori naglašavaju različite događaje i sustave kao relevantne. U nastavku je dan kratak pregled bitnih otkrića u razvoju sustava od 60-tih do danas.

Tijekom 60-tih godina započeo je sustavno istraživanje korištenja računala za potporu planiranja i donošenja odluka u poslovnim procesima. Polovicom desetljeća na tržištu su se pojavila snažna IBM-ova računala koja su omogućila razvoj i uspostavu složenih upravljačkih

informatičkih sustava. Krajem desetljeća pojavila su se snažnija računala koja su omogućila uspostavu i samih sustava za potporu odlučivanju. [6]

Glavna povijesna prekretnica je Scott Mortonova disertacija terenskog istraživanja na Sveučilištu Harvard. Scott Mortonovo istraživanje obuhvatilo je izgradnju, implementaciju, a zatim i testiranje interaktivnog sustava upravljanja. Student Andrew McCosh tvrdi da je koncept sustava za podršku odlučivanju prvi artikulirao Scott Morton u veljači 1964. godine u podrumskom uredu Harvard poslovne škole u njihovoj raspravi o Mortonovoj disertaciji. Tijekom 1966. Scott Morton istraživao je kako računala i analitički modeli mogu pomoći menadžerima napraviti ponavljajuću ključnu poslovnu odluku. Proveo je eksperiment u kojem menadžeri zapravo koriste Upravljački sustav za odlučivanje (Management Decision System - MDS) u koordiniranju planiranja proizvodnje opreme za praonice. [7]

Scott Mortonov daljnji rad u području rezultirao je izdavanjem knjige „Management Decision System: Computer-Based Support for Decision Making“ 1971. godine.

Početkom 70-tih godina objavljen je niz članaka iz područja potpore odlučivanju. U članku autora Gorrya i Scott Mortona objavljenom u časopisu „Sloan Management Review“ 1971. godine po prvi put se pojavljuje pojam Decision Support System. U istom časopisu 1971. godine objavljen je značajan rad autora T. P. Gerritya „The Design of Man-Machine Decision Systems: An application to Portfolio Management“. U okviru članka Gerrity je ostvario sustav za potporu donošenja odluka u ulaganju dionica te upravljanju portfolijom dionica.

John D. C. Little s instituta Massachusetts Institute of Technology razvio je 1975. godine sustav Brandaid. Sustav je namijenjen potpori donošenju odluka u proizvodnji, promociji, oglašavanju i definiranju cijena proizvoda. Dodatno, Little je definirao četiri kriterija sustava za potporu odlučivanju robusnost, potpunost relevantnih detalja te jednostavnost korištenja i upravljanje. Kriteriji se koriste i za ocjenu suvremenih sustava.

S. Alter objavio je 1980. godine rezultate doktorskog rada u knjizi „Decision Support Systems: Current Practice and Continuing Challenge“. Rad sadrži definiciju sustava za potporu odlučivanju i precizne primjene sustava. U okviru rada proveo je analizu 56 sustava. Značajna je i Alterova kategorizacija sustava zasnovana na općenitim funkcijama koje sustav obavlja.

Autori R. Bonczek, C. Holsapple i A. Whinston 1981. godine definirali su teoretsku arhitekturu sustava za potporu odlučivanju. Arhitektura se sastoji od četiri općenite

komponente za obradu problema i prezentacijski sloj. U svome radu objašnjavaju vezu potpore odlučivanju s područjem umjetne inteligencije i ekspertnih sustava.

R. Sprague i E. Carlson 1982. godine objavili su knjigu „Building Effective Decision Support Systems“. Koja sadrži općenite upute za izgradnju sustava za potporu odlučivanju.

Tijekom 90-tih godina dolazi do razvoja tehnologije skladištenja podataka i OLAP (eng. On Line Analytical Processing - OLAP). Razvoj ovih tehnologija omogućava razvoj posebne vrste sustava za potporu odlučivanju - Informacijskih sustava za izvršne rukovoditelje (eng. Executive Information Systems - EIS).

S pojavom WEB-a i globalne mreže Internet stvara se novi oblik sustava za potporu odlučivanju - sustav zasnovan na WEB-u. Neka od svojstava ovih sustava su: poslužitelj je smješten na udaljenom računalu i korisnik mu pristupa jednostavnim klijentom (WEB preglednik), orijentiranost korištenju računalne mreže za pristup različitim udaljenim izvorima podataka.

Razvoj sustava za potporu odlučivanju nastavlja se i u današnje vrijeme. Značajni utjecaj na smjer istraživanja i razvoja imaju različite tehnološke promjene koje omogućavaju ostvarivanje novih oblika sustava. [6]

#### **4.2. Vrste DSS-a**

Postoji više kategorizacija sustava [6] za potporu odlučivanju. Jedna od njih je kategorizacija zasnovana na dominantnoj komponenti u arhitekturi sustava. Ta kategorizacija dijeli sustave na sljedeće kategorije koji su u nastavku rada detaljnije opisani:

- DSS zasnovan na modelu
- DSS zasnovan na podacima
- DSS zasnovan na komunikacijama
- DSS zasnovan na dokumentima
- DSS zasnovan na znanju
- DSS zasnovan na WEB-u

Sustavi za potporu odlučivanju mogu se podijeliti i na unutarorganizacijske i međuorganizacijske. Unutarorganizacijski koriste se isključivo unutar jedne tvrtke. Međuorganizacijski su ponuđeni i korisnicima izvan tvrtke koja je vlasnik sustava.

Ovisno o primjeni, sustavi se mogu podijeliti na općenite i specifične. Općeniti sustavi mogu se koristiti za širi skup primjena (npr. upravljanje projektom). Poseban oblik općenitog



sustava su okoline za potporu odlučivanju. Specifični sustavi izrađeni su isključivo za korištenje u jednom području (npr. financijske odluke, analiza tržišta).

Jedna od ranijih kategorizacija definira kategorizacije sustava prema općenitim funkcijama sustava:

- podatkovni: sustav koji omogućava izravan pristup i analizu nad podacima (transakcijski sustavi)
- analiza podataka: sustavi koji omogućavaju manipulaciju nad podacima kroz pripremljene forme, npr. analizu budžeta i investiciju
- analiza informacija: sustavu koji omogućavaju pristup skupu modela, npr. analiza konkurencije, prognoza prodaje na tržištu
- financijski: sustavi analiziraju posljedice akcija (modeli what-if)
- reprezentacijski: sustavi izračunavaju posljedice akcija na osnovi modela zasnovanog na vezama, npr. odziv tržišta, analiza rizika
- optimizacijski: sustavi za zadani unos izračunavaju optimalno rješenje, npr. raspoređenje resursa
- sugestivni: sustavi slijede niz [6]

#### **4.2.1. DSS zasnovan na modelu**

DSS zasnovan na modelu [8] naglašava pristup i manipulaciju kvantitativnim modelom (npr. algebarskim, financijskim, optimizacijskim ili simulacijskim modelom). Jednostavni analitički alati temeljeni na algebarskom modelu, daju najelementarniju razinu funkcionalnosti. DSS zasnovan na modelu koristi podatke i parametre, koje pružaju donositelji odluke, kako bi im pružali potporu u analizi situacije. Kvantitativni modeli pružaju funkcionalnost za ovu vrstu sustava. Korisnici mogu unositi podatke ili ih preuzimati iz specijalizirane baze podataka. [8]

#### **4.2.2. DSS zasnovan na podacima**

DSS zasnovan na podacima [8] naglašava pristup i manipulaciju u vremenskom nizu internih podataka poduzeća i, u nekim sustavima, vanjskih podataka u realnom vremenu. Jednostavni sustavi dokumenata do kojih se pristupa pomoću upita i pristupnih alata omogućuje najosnovniju razinu funkcionalnosti. Sustavi skladištenja dokumenata omogućavaju pristup do veće količine podataka i dodatne funkcionalnosti. Sustavi s analitičkim procesom nude

najvišu razinu funkcionalnosti. Sustavi poslovne inteligencije za operativno ili strateško korištenje najčešće su zasnovani na podacima. BAM (eng. Business Activity Monitoring - BAM) i BPM (eng. Business Process Management - BPM) DSS zasnovan na podacima koriste podatke u stvarnom vremenu kako bi pomogli u operativnom praćenju značajki. Dominantna komponenta u tim sustavima je snimanje, pohrana i dohvat strukturiranih podataka. [8]

#### **4.2.3. DSS zasnovan na komunikacijama**

DSS sustavi zasnovani na komunikacijama [8] naglašavaju komunikaciju, suradnju i zajedničku podršku odlučivanju korištenjem tehnologije. Jednostavna oglasna ploča ili e-mail je najelementarnija razina funkcionalnosti. Grupiranje je podskup šireg koncepta pod nazivom suradničko računalstvo. DSS sustavi zasnovani na komunikacijama omogućavaju dvjema ili više osobama da komuniciraju jedni s drugima, dijele informacije i koordiniraju svoje aktivnosti. GDSS (eng. Group Decision Support Systems - GDSS) može biti primarno zasnovan na komunikacijama ili zasnovan na modelu. Neki GDSS-i omogućuju većem broju korisnika zajedničku suradnju pomoću raznih softverskih alata. Primjeri alata koji se koriste kod DSS-a zasnovanog na komunikacijama su audio konferencije, oglasne ploče, WEB-konferencije, virtualni svjetovi, računalno podržani licem u lice softveri itd. Dominantne komponente arhitekture su komunikacijske sposobnosti. [8]

#### **4.2.4. DSS zasnovan na dokumentima**

DSS zasnovan na dokumentima [8] integrira razne tehnologije pohranjivanja i obrade radi pružanja kompletnog pretraživanja i analize dokumenata. Primjeri dokumenata obuhvaćaju postupke, proizvodne specifičnosti, katalog sadržaja, zapisnike sa sjednica, korporativne podatke i važne poruke. Tražilica je snažan alat za donošenje odluke zasnovan na dokumentima. DSS zasnovan na dokumentima je jedan tip sustava za upravljanje znanjem. Dokumenti i upravljanje dokumentima osiguravaju funkcionalnost ove vrste DSS-a. [8]

#### **4.2.5. DSS zasnovan na znanju**

DSS zasnovan na znanju [8] sugerira ili preporučuje mjere aktivnosti za menadžere. Ovi DSS sustavi su sustavi osoba-računalo sa specijaliziranom mogućnošću rješavanja problema. Ovi sustavi pohranjuju i primjenjuju znanje za razne specifične poslovne probleme. Ti problemi uključuju klasifikaciju i konfiguraciju zadataka kao što su odobrenje kredita, upravljanje rizicima i politika tvrtke. DSS zasnovan na znanju koristi vještačku inteligenciju i statističke


tehnologije. Skladišta znanja i procesna znanja su dominantne komponente u arhitekturi ovih sustava. [8]

#### 4.2.6. DSS zasnovan na WEB-u

WEB se danas sve više koristi kao klijent/server platforma u mnogim poslovnim organizacijama zbog niskih troškova softvera, instalacije i održavanja. Samim tim i rješenja bazirana na WEB-u imaju olakšan pristup, analizu i distribuciju informacija iz baze podataka organizacije, a putem OLAP-a. OLAP je tehnologija koja omogućava manipulaciju podacima organizacije kroz više dimenzija kao što su proizvod, vrijeme, mjesto itd. Internet i intranet su tijekom prethodnih godina pružili široku mogućnost izgradnje DSS-a koji može da se nosi s problemima globalne prirode. HTML 2.0 u obliku tablica je prekretnica u razvoju WEB zasnovanih DSS-a. DSS zasnovan na WEB-u je sustav koji komunicira s informacijama ili alatima za podršku odlučivanju kroz WEB okruženje (internet, ekstranet i intranet), koristeći WEB tehnologije. Na ovaj način donošenje odluka je efikasnije, jer se smanjuju troškovi implementacije modela, a i sama razmjena informacija je bolja.

Power D. J. je definirao DSS zasnovan na WEB-u, kao računalni sustav koji pruža informacije za podršku odlučivanju ili alate za podršku odlučivanju menadžerima ili poslovnim analitičarima pomoću WEB pretraživača kao što je Internet Explorer. [9]

Komponente DSS-a zasnovanog na WEB-u prikazani su na Slici 4.1.



Slika 4.1 Komponente DSS-a zasnovanog na WEB-u [9]

## 5. ANALITIČKO HIJERARHIJSKI PROCES (AHP METODA)

Proces donošenje odluke predstavlja jedan od najvažnijih problema, koji se pojavljuje u svakodnevnoj djelatnosti. Donošenje odluke koje su povezane sa situacijama iz svakodnevnog ili poslovnog okruženja poput izbora strategije tvrtke, tehničkog rješenja, mjesta, visine i dinamike ulaganja ovise o velikom broju međusobno povezanih i često potpuno konfliktnih kriterija. Problem se javlja kako ispravno procijeniti važnost tih kriterija, kako izvesti sustav prioriteta koji može dovesti do dobre odluke o izboru najbolje alternative. [10]

Pod pojmom višekriterijskog odlučivanja podrazumijeva se postupak izbora jedne od mogućih alternativa odluke. Glavni elementi problema odlučivanja su ciljevi koji se žele postići odlukom, alternative između kojih se biraju i kriteriji koji se koriste kod izbora. Pod ciljem podrazumijeva se stanje sustava koje želimo postići odlukom. U nekim slučajevima se taj cilj može opisati preciznije, npr. kod odluke koliko temeljito pripremiti ispit može se postaviti cilj „Želim postići prosječnu ocjenu na studiju višu od 4.5“, a ponekad se cilj ne kvantificira. Kriteriji su atributi kojima se opisuju alternative i njihova svrha je da direktno ili indirektno daju informacije o tome u kojoj mjeri se pojedinom alternativom ostvaruje željeni cilj. U danom problemu odlučivanja svi kriteriji nisu jednako važni, a relativna važnost kriterija proizlazi iz preferencija donositelja odluke što je povezana s njegovim vrijednosnim sustavom i ostalim psihološkim karakteristikama. Dakle, prisutna izrazita subjektivnost. Kod izbora kriterija i određivanja njihovih važnosti treba uzeti u obzir i druge specifičnosti donositelja odluke. Npr. odličan učenik srednje škole će se, pri izboru fakulteta na kojem želi studirati, služiti kriterijima različitim od onih koje će koristiti učenik koji je jedva prošao na državnoj maturi. Ukoliko oni i koriste neke zajedničke kriterije, vrlo je vjerojatno da oba ne daju jednaku važnost istim kriterijima. Konačna odluka uvelike ovisi o važnostima pojedinih kriterija. [11]

Metode koje se koriste za uspoređivanje i rangiranje alternativa na temelju podataka iz tablice odlučivanja, moraju uzeti u obzir prednosti koje neka alternativa ima u odnosu na ostale, usporediti te prednosti s njezinim nedostacima i sve to izraziti jednim brojem. Ukoliko kriteriji imaju različite važnosti, treba uzeti u obzir i njihove težine. Metode koje se mogu upotrebiti u ovoj situaciji temelje se na određenim pretpostavkama koje se karakteriziraju matematički. Ovisno o tome kakav je model načinjen, potrebno je poznavati odgovarajuću matematičku teoriju da bi se on riješio. Ukoliko se matematički model koji se primjenjuje u analizi problema odlučivanja temelji na jednostavnijim matematičkim tehnikama, njegov

rezultat ima ograničenu vrijednost u primjeni i teže je argumentirati odluku. Najpoznatije metode za uspoređivanje i rangiranje alternativa u problemima odlučivanja su Analitički hijerarhijski proces (AHP), ELECTRE i PROMETHEE. [12]

ELECTRE su postupci višekriterijske optimizacije koji omogućuju izbor najbolje varijante tzv. selekciju, rangiranje i sortiranje varijanata, ovisno o verziji ELECTRE-a, nekog problema vodeći računa o kriterijima i preferencijama donositelja odluke. ELECTRE postupak je razvijen za djelomično uređenje skupa rješenja na osnovi preferencije donositelja odluke. Na osnovi preferencija konstruira se graf čiji čvorovi predstavljaju moguća rješenja, a jezgra (kernel) definira preferirana rješenja. ELECTRE postupak je pogodan za korištenje u slučajevima gdje su kriterijske funkcije slabo definirane.

PROMETHEE je postupak koji se koristi za dobivanje djelomičnog (PROMETHEE I) ili potpunog rangiranja varijanti (PROMETHEE II). PROMETHEE postupak se temelji na proširenju pojma kriterija uvođenjem funkcije preferencije, koja daje preferenciju donositelja odluke za varijantu A u odnosu na varijantu B. Funkcija preferencije definira se za svaki kriterij posebno, a njena vrijednost je između 0 i 1. Što je manja vrijednost funkcije, veća je indiferencija donositelja odluke, odnosno što je vrijednost bliže 1 veća je njegova preferencija. U slučaju stroge preferencije, vrijednost funkcije preferencije jednaka je 1. Šest različitih tipova funkcije (običan kriterij, kvazikriterij, kriterij s linearnom preferencijom, razinski kriterij, kriterij s linearnom preferencijom i područjem indiferentnosti te Gaussov kriterij) pokrivaju većinu slučajeva koji se pojavljuju u praktičnoj primjeni za koje donositelj odluke mora definirati najviše dva parametra. Upotreba na prethodni način oblikovanih kriterija dopušta konstrukciju procijenjene relacije (grafa) „višeg ranga“. Korištenjem procijenjene relacije „višeg ranga“, postiže se djelomično (PROMETHEE I), odnosno potpuno rangiranje varijantnih rješenja (PROMETHEE II). [13]

U nastavku rada detaljno je razrađena AHP metoda i njezina primjena kod rješavanja problema višekriterijskog odlučivanja, te njena programska podrška Expert Choice.

## 5.1. AHP metoda

Analitički hijerarhijski proces utemeljio je 1980. godine Thomas L. Saaty (1). AHP predstavlja jednu od najpoznatijih metoda stručne analize scenarija i donošenja odluka konzistentnim ocjenjivanjem hijerarhija koje se sastoje od ciljeva, scenarija, kriterija i alternativa.

AHP najprije omogućuje interaktivno strukturiranje (oblikovanje hijerarhije) problema kao pripremu scenarija odlučivanja. Hijerarhijski strukturiran model odlučivanja sastoji se od cilja, kriterija, nekoliko mogućih nivoa podkriterija i alternativa. Cilj je uvijek na vrhu i nije ga moguće uspoređivati s niti jednim drugim elementom. U prvom nivou postoji  $n$  kriterija koji se u parovima svaki sa svakim uspoređuju u odnosu na prvi nadređeni element na višem nivou, ovdje je to cilj na nultom nivou. Potrebno je  $n*(n-1)/2$  usporedbi. Ova procedura se primjenjuje kroz hijerarhiju prema dolje. Na kraju se vrši analiza svih ocjenjivanja i po strogo utvrđenom matematičkom modelu određuju se težinski faktori svih elemenata hijerarhije. [10] AHP metoda koristi tablični zapis podataka za uspoređivanje i rangiranje alternativa, pri odlučivanju koja je od alternativa u prednosti u odnosu na ostale. AHP metoda uspoređuje prednosti i nedostatke pojedinih alternativa i u konačnici daje prioritete alternativa u obliku jednog broja. Kriteriji za odabir određene alternative mogu imati različite vrijednosti zbog čega im se dodjeljuju težine. AHP metoda temelji se na uspoređivanju alternativa u parovima. Težine pojedinih kriterija određuju se uspoređivanjem kriterija u parovima te određivanjem koliko je prvi kriterij važniji od drugog kriterija. AHP je izgrađena na kvalitetnoj i jednostavnoj teoretskoj osnovi. [14]

Vrijednost ove metode je u tome što se kroz postupak izvodi zaključak i sinteziraju informacije od donositelja odluke i drugih sudionika koji posjeduju saznanja o problemu, da bi se identificirao problem i da se suglase stavovi o njegovoj strukturi.

AHP je vrlo fleksibilna metoda jer dozvoljava da kod složenih problema s mnogo kriterija i dovoljno velikim brojem alternativa, relativno lako pronađu odnosi između kriterija i alternativa, te da se prepozna njihov eksplicitni ili relativni utjecaj i značaj u realnom okruženju te da se odredi dominantni utjecaj jednog kriterija na drugi. Ova metoda uzima u obzir činjenicu i da se i najsloženiji problemi daju razgraditi na hijerarhiju i to tako da se u analizu uključe kvantitativni i kvalitativni aspekti problema. AHP povezuje i drži povezane sve dijelove hijerarhije, pa je lako moguće uočiti na koji način promjena jednog kriterija utječe na ostale kriterije i alternative. [10]

## 5.2. Provedba AHP metode

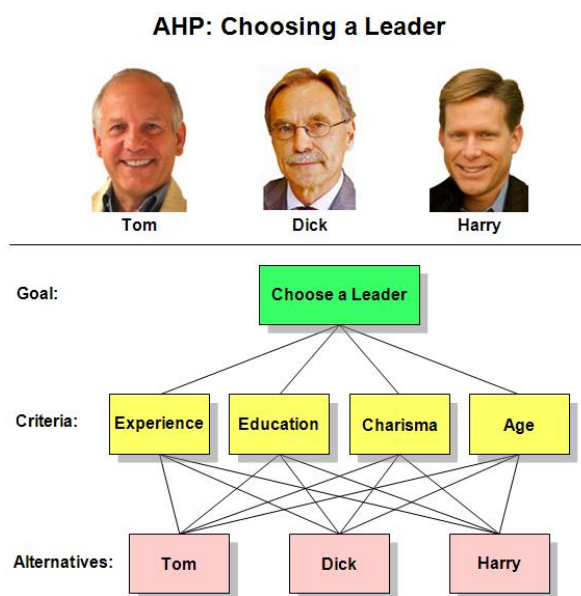
Provedbu AHP metode može se jednostavno opisati u *četiri koraka*:

*Korak 1:* Problem se razlaže na hijerarhiju cilja, kriterija, podkriterija i alternativa. To je vrlo kreativan i važan dio odlučivanja. Strukturiranje problema odlučivanja u hijerarhiju je od temeljne važnosti za proces AHP metode. Hijerarhija prikazuje veze između elemenata jedne

razine s onima na nižoj razini. Ta povezanost proteže se do najniže razine hijerarhije i na taj način svaki element je povezan sa svim ostalim elementima, barem na neizravan način. Obrnuta struktura stabla je slična strukturi hijerarhije. Saaty sugerira koristan način izrade hijerarhijske strukture od cilja prema dolje, a zatim od alternativa prema gore sve dok razine dvaju procesa ne budu povezane na takav način da omogućavaju usporedbe. [15]

Raspoređivanje svih elemenata u hijerarhiju omogućuje cjelokupni pregled složenih veza i pomaže donositelju odluka procijeniti da li su elementi u svakoj razini iste veličine (značaja) da bi se mogli ispravno uspoređivati. Element u zadanoj razini ne mora funkcionirati kao kriterij za sve elemente u razini ispod. Svaki element može predstavljati različiti dio problema pa hijerarhija ne mora biti kompletna. Kod konstrukcije hijerarhije bitno je uzeti u obzir čimbenike koji okružuju problem te identificirati probleme ili značajke koje doprinose rješenju. [12]

Na Slici 5.1 prikazan je jednostavan primjer hijerarhijske strukture. Cilj je odabir najprikladnijeg vođe iz grupe od tri kandidata. Kriteriji koji se razmatraju su iskustvo, obrazovanje, karizma i dob.



**Slika 5.1 Primjer hijerarhijske strukture [16]**

*Korak 2:* U svakom čvoru hijerarhijske strukture pomoću Saatyve skale u parovima se međusobno uspoređuju elementi tog čvora koji se nalaze neposredno ispod njega i izračunaju se njihove lokalne težine. Pritom se kriteriji međusobno uspoređuju u parovima u odnosu na to koliko je jedan od njih važniji za postizanje cilja od drugog. Alternative se međusobno uspoređuju u parovima po svakom od kriterija procjenjujući u kojoj mjeri se po tom kriteriju

jednoj od njih daje prednost u odnosu na drugu. S tim da se cilj nalazi na vrhu hijerarhijske strukture i nije ga moguće uspoređivati niti s jednim drugim elementom.

**Korak 3:** Iz procjene relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema izračunaju se lokalne težine kriterija i podkriterija, a na posljednoj razini prioriteta alternativa. Ukupni prioritet alternativa izračunaju se tako da se njihovi lokalni prioriteti ponderiraju s težinama svih čvorova kojima pripadaju gledajući od najniže razine u hijerarhijskom modelu prema najvišoj i zatim zbroje.

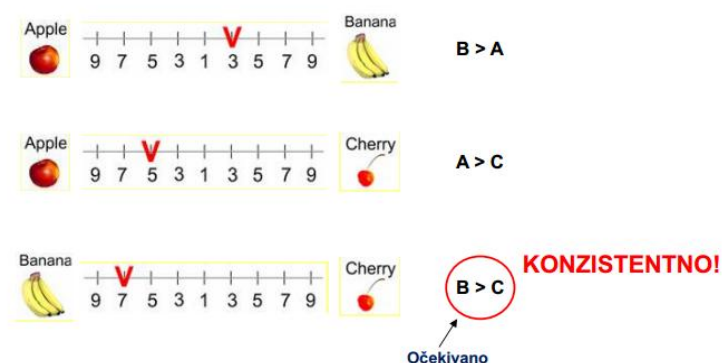
**Korak 4:** Provodi se analiza osjetljivosti s ciljem da se vidi u kojoj mjeri se promjene ulaznih podataka odražavaju na ukupne prioritete alternativa. [10]

### 5.3. Konzistentnost

AHP metoda spada u popularne metode zato što ima sposobnost da identificira i analizira nekonzistentnosti donositelja odluka u procesu prosuđivanja i vrednovanja elemenata hijerarhije. Čovjek je, naime, rijetko konzistentan pri procjenjivanju vrijednosti ili odnosa kvalitativnih elemenata u hijerarhiji. AHP na određeni način ublažava ovaj problem tako što mjeri stupanj konzistentnosti i o tome obavještava donositelja odluke.

Nekonzistentnost procjena moguće je najjednostavnije objasniti pomoću primjera. Npr. ako se tvrdi da je A mnogo većeg značaja od B, B većeg značaja od C i C nešto većeg značaja od A, nastaje nekonzistentnost u rješavanju problema i smanjuje se pouzdanost rezultata.

Na Slici 5.2 imamo primjer konzistentnog odlučivanja.



**Slika 5.2. Primjer konzistentnosti [17]**

Da bi se izmjerio stupanj konzistentnosti (CR) potrebno je prvo izračunati indeks konzistentnosti (CI) prema (1):

$$CI = \frac{\lambda_{\max} - n}{n - 1}, \quad (1)$$

gdje je  $\lambda_{\max}$  maksimalna vlastita vrijednost matrice uspoređenja, a  $n$  broj usporedbi. Što je  $\lambda_{\max}$  bliže broju  $n$ , manja će biti nekonzistentnost.



Da bi se izračunao  $\lambda_{\max}$ , prvo treba pomnožiti *matricu uspoređenja* s *vektorom težinskih koeficijenata* da bi se odredio vektor  $b$  (2):

$$\begin{bmatrix} a_{11} & a_{12} & \dots & \dots & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & \dots & \dots & a_{2n} \\ \cdot & & & & & \cdot \\ \cdot & & & & & \cdot \\ a_{n1} & a_{n2} & \dots & \dots & \dots & a_{nn} \end{bmatrix} x \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \cdot \\ \cdot \\ b_n \end{bmatrix} \quad (2)$$

Dijeljenjem korespondnih elemenata vektora  $b$  i  $w$  dobije se (3):

$$\begin{bmatrix} \frac{b_1}{w_1} \\ \frac{b_2}{w_2} \\ \cdot \\ \cdot \\ \frac{b_n}{w_n} \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \cdot \\ \cdot \\ \lambda_n \end{bmatrix} \quad \text{te je konačno } \lambda_{\max} = \frac{1}{n} * \sum_{i=1}^n \lambda_i . \quad (3)$$

Konačno, stupanj konzistentnosti (CR) predstavlja omjer indeksa konzistentnosti (CI) i slučajnog indeksa (RI) (4):

$$CR = \frac{CI}{RI} . \quad (4)$$

Slučajni indeks konzistentnosti (RI) je indeks konzistentnosti za matrice reda  $n$  slučajno generiranih usporedbi u parovima, čime su dobiveni podaci u Tablici 5.1.

**Tablica 5.1**                      **Vrijednost RI slučajnih indeksa (Saaty, 1980.) [18]**

N	1	2	3	4	5	6	7	8	9	10
RI	0	0	0,52	0,89	1,11	1,25	1,35	1,4	1,45	1,49

Ako je  $CR$  manji od 0.10 rezultat je dovoljno točan i nema potrebe za korekcijama u uspoređenjima i ponavljanja proračuna. Ako je  $CR$  veći od 0.10, rezultate bi trebalo ponovo analizirati i ustanoviti razloge nekonzistentnosti i ukloniti ih djelomičnim ponavljanjem uspoređenja u parovima. Ako ponavljanje procedure u nekoliko koraka ne dovede do sniženja  $CR$ -a do tolerantnog limita 0.10, sve rezultate treba odbaciti i ponoviti cijeli postupak od početka. Međutim treba napomenuti da u praksi je čest slučaj da  $CR$  bude veći od 0.10, a da se izabrana alternativa ipak zadrži kao najbolja.

#### 5.4.            Saatyeva skala

U procjeni vrijednosti omjera težina kriterija i važnosti alternativa pomaže Saatyeva skala. Ona pomaže procijeniti omjere važnosti dvaju kriterija kada se njihove vrijednosti izražavaju kvantitativno, kvalitativno i u različitim mjernim jedinicama. Saatyeva skala je omjerna skala

koja ima pet stupnjeva intenziteta i četiri međustupnja, a svakom od njih odgovara vrijednosni sud o tome koliko puta je jedan kriteriji važniji od drugog.

Iz Tablice 5.2 vidljivo je da je maksimalna vrijednost intenziteta važnosti 9 koja se može dati omjeru važnosti kriterija. Također, ista skala se koristi i kod uspoređivanja alternativa, ali u tom slučaju se vrijednosti sa skale interpretiraju kao prosudbe koliko puta veća prednost (važnost) se daje jednoj alternativu u odnosu na drugu. [10]

**Tablica 5.2                      Saatyeva skala [10]**

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dva kriterija ili alternativa jednako doprinose cilju
3	Umjereno važno	Na temelju iskustva i procjena daje se umjerena prednost jednom kriteriju ili alternativu u odnosu na drugu
5	Strogo važnije	Na temelju iskustva i procjena strogo se favorizira jedan kriterij ili alternativa u odnosu na drugi
7	Vrlo stroga, dokazana važnost	Jedan kriterij ili alternativa izrazito se favorizira u odnosu na drugi; njegova dominacija dokazuje se u praksi
9	Ekstremna važnost	Dokazi na temelju kojih se favorizira jedan kriterij ili alternativa u odnosu na drugi potvrđeni su s najvećom uvjerljivošću
2, 4, 6, 8		Međuvrijednosti

### **5.5.            Prednosti i nedostaci AHP**

Prednosti i nedostaci AHP metode predmet su brojnih značajnih rasprava između stručnjaka na području višekriterijskih analiza. Kako gotovo sve u životu ima dobre i loše, ili barem bolje i lošije strane, tako je i s AHP metodom. U nastavku su navedene neke od najznačajnijih prednosti i nedostataka u primjeni AHP metode.

#### **Prednosti AHP:**

- Prednosti AHP u odnosu na druge višekriterijske metode su njezina fleksibilnost, intuitivna bliskost donosiocima odluka i sposobnost provjere nekonzistentnosti. Općenito, korisnici smatraju da je metoda parne usporedbe unosa podataka jednostavna i praktična.
- AHP metoda ima izrazitu prednost u tome što razgrađuje problem odlučivanja u njegove sastavne dijelove i gradi hijerarhiju kriterija. Ovdje postaje jasna važnost svakog elementa (kriterija).

- AHP pomaže zabilježiti i subjektivne i objektivne mjere procjenjivanja. Dok pruža koristan mehanizam za provjeru dosljednosti mjera evaluacije i alternativa, AHP smanjuje pristranost u odlučivanju.
- AHP metoda podržava skupno donošenje odluka konsenzusom, izračunavanjem pojedinih parnih usporedbi geometrijskim načinom.
- AHP je jedinstveno pozicionirana da bi pomogla modelima situacija neizvjesnosti i rizika, budući da je sposobna za izvođenje mjernih ljestvica tamo gdje mjere obično ne postoje. [19]
- U AHP analizu mogu se uključiti kriteriji i alternative s kvalitativnim i kvantitativnim iznosima.
- AHP metoda je primjenjiva u rješavanju vrlo kompleksnih problema odlučivanja.
- Implementacija ocjenjivanja važnosti kriterija na način sličan ljudskom.
- Širokog područja primjene i dobre računalne implementacije (Expert Choice). [17]

#### **Nedostaci AHP:**

- Mnogi istraživači dugo su promatrali neke slučajeve u kojima se mogu pojaviti nepravilnosti u rangiranju kada se koristi AHP ili neke od njezinih varijanti. Ova promjena u rangiranju će se vjerojatno pojaviti kada se doda kopija ili približna kopija postojeće opcije skupu alternativa koje se procjenjuju. Triantaphyllon [19] (2001.) je dokazao da promjena u rangiranju nije moguća kada se koristi multiplikativna varijanta. Prema Beltonu [19] (1986.) te Beltonu i Gearu [19] (1997) za promjene u rangiranju kod AHP metode odgovorno je različito interpretiranje težina kriterija. Međutim, AHP i neke od njegovih varijanti mnogi smatraju najpouzdanijom metodom višekriterijskog odlučivanja.
- AHP metoda može se smatrati kao kompletna agregacijska metoda aditivnog tipa. Problem s takvom agregacijom je da se može pojaviti kompenzacija između dobrih rezultata na nekim kriterijima i loših rezultata na drugim kriterijima. Zbog takvih agregacija često se mogu izgubiti detaljne i često važne informacije.
- S AHP metodom problem odluke se razlaže na nekoliko podsustava, u okviru kojih i između kojih treba biti izvršen znatan broj parnih usporedbi. Ovaj pristup ima nedostatak u tome da broj potrebnih parnih usporedbi može postati vrlo velik, i samim time sam proces zahtjeva dosta vremena.
- Sljedeći nedostatak AHP metode je umjetno korištenje ograničenja korištenja skale od 1 do 9. Ponekad, donositelju odluka može biti teško razlikovati alternative i donijeti prosudbu o tome da li je jedna alternativa i koliko puta važnija od druge. Također, AHP metoda se ne može nositi s činjenicom da je alternativa A 25 puta važnija od alternative B. Zbog rasprave o

---

ograničenjima bodova skale, Hajkowicz [19] (2000.) je izmijenio postupak u svojoj studiji koristeći dvobodovnu ljestvicu, zbog vremenskih ograničenja postavljenih donositelju odluke. Dakle, donositelji odluke samo su naznačili da li je kriterij bio više, manje ili jednako važan. [19]

- Principijelno troškovi mogu biti uključeni u AHP model. Uključivanjem troškova (npr. cijena koštanja) unutar AHP model možemo dobiti preskupu alternativu s velikim brojem benefita, a zapravo se traži jeftina alternativa sa što je moguće većim brojem benefita. Zbog toga kod kompleksnih odlučivanja predlaže se zasebno razmatranje troškova alternativa od razmatranja benefita koje iste donose. [17]

## 6. EXPERT CHOICE SOFTVERSKA APLIKACIJA

Efikasan softverski alat za rješavanje problema višekriterijskog odlučivanja jest Expert Choice. To je alat s jakim značajkama za analizu odluka na razini organizacije. EC je robusna aplikacija namijenjena za stolno računalo, koja omogućuje timovima prioritetno sortiranje i prioritetiziranje alternativa, te pouzdano donošenje odluka o alternativama za postizanje željenih ciljeva. [14]

### 6.1. Razvoj programa Expert Choice

U ranim 1980-im, dr. Ernest Forman [12], dr.sc. profesor Upravne znanosti na sveučilištu George Washington u školi za poslovnu i javnu upravu, razvio je program Expert Choice prilagođavajući AHP metodu višekriterijskog odlučivanja za uporabu s osobnim računalima te mu je odobreno nekoliko prvih softverskih patenata za osobna računala. Od pomaganja preokreta IBM-a do pomaganja Združenom stožeru pri određivanju prioriteta vojne prijetnje. 1980-tih godina Expert Choice je napravio svoj trag na komercijalnom tržištu u vodstvu vodećih tvrtki poput Xerox i Rockwell Internationala kroz inicijative složenih strateških planiranja. U 1990-tim proširila se prisutnost EC-a u krugu Američke savezne vlade, gdje se EC primjenjivao kao pomoć službenicima u Ministarstvu ratnih veterana i Upravi socijalne sigurnosti, zatim u Ministarstvu obrane i drugim federalnim agencijama sa strateškim planiranjem, te projektima za odabir i raspodjelu resursa. Trenutno, vlada SAD-a koristi EC za raspodjelu resursa u vrijednosti više od 120 milijardi američkih dolara godišnje. [12]

### 6.2. Značajke Expert Choice-a

Kako je već rečeno, jedan od efikasnih alata za rješavanje višekriterijskog problema je EC. EC je u potpunosti sposoban podržati sve korake karakteristične za primjenu AHP metode. Program omogućuje strukturiranje hijerarhijskog modela problema odlučivanja na više načina, te uspoređivanje u parovima također na nekoliko načina. Posebnu vrijednost programu daju različite mogućnosti provođenja analize osjetljivosti koje se temelje na vizualizaciji posljedica promjena ulaznih podataka. Također, program omogućava kreiranje različitih izvješća. [10]

EC dozvoljava mogućnost prosudbe, odnosno uspoređivanje u parovima, na numerički, grafički ili verbalni način, gdje svaka prosudba izražava odnos jednog elementa u odnosu na drugi element. Kada se radi usporedba u socijalnom, psihološkom, odnosno političkom

kontekstu, jednostavnije je koristiti verbalni način prosudbe. Dok kod usporedbe ekonomskih ili nekih drugih mjerljivih faktora, numerički i grafički način usporedbe može biti prednost, iako je sasvim prihvatljivo koristiti verbalni način rada i u tom slučaju. [20]

Kada se radi o grupnom donošenju odluka, EC znatno olakšava komunikaciju uzimajući obzir razmatranje cijele grupe ljudi, te su ona u konačnici dostupna jezgrovito i razumljivo svim sudionicima. Na taj način povećava se mogućnost za postizanje konsenzusa, te se umanjuje efekt pobjede jačeg člana grupe. Budući da su svi sudionici upućeni u specifične aspekte problema, omogućena je lakša podjela njihovih stručnosti s drugima u grupi. EC omogućuje stvaranje grupnih procjena u modelu parova i modelu apsolutne komparacije. EC međutim ne može zamijeniti ljudske procjene. Čak i kada postoje detaljne i jasne informacije o budućnosti, ljudske procjene o vrijednostima i izborima i dalje su osnova za donošenje dobrih odluka. EC je dakle sustav za analizu, sintezu i potkrepljivanje složenih odluka i procjena, koji značajno povećava sposobnost donošenja kvalitetnih i učinkovitih odluka unatoč kompleksnosti. [12]

### **6.3.        Praktična primjena Expert Choice-a**

Expert Choice može se koristiti za bilo koju odluku gdje je potrebno:

- prioritetizirati ciljeve za strateško planiranje,
- raspodijeliti resurse,
- ispitati alternative i donijeti odluku.

Ovo su neke od najčešćih primjena korištenja Expert Choice-a na području donošenja odluka:

- projektni i proizvodni menadžment
- izračun proračunskog kapitala
- strateško planiranje
- menadžment rizika
- strategija marketinga i inovacija
- menadžment ljudskih potencijala
- donošenje generalnih odluka
- studijima trgovine
- transparentnost savezne, državne i lokalne samouprave [21]


## 6.4. Struktura Expert Choice modela

Kako je već spomenuto Expert Choice temelji se na AHP metodi, u kojoj se podaci i intuicije organiziraju u logičku hijerarhijsku strukturu. Expert Choice organizira razne elemente problema u hijerarhiju sličnu strukturi obiteljskog stabla, gdje se svaki element u strukturi naziva presjecištem. Na najvišoj razini strukture nalazi se presjecište cilja. Na razini ispod kriteriji i podkriteriji, te na najnižoj alternative. U hijerarhijskoj strukturi Expert Choice-a jednostavni modeli imaju presjecišta kriterija ispod cilja i presjecišta alternativa ispod svakog presjecišta kriterija. Složeniji modeli mogu imati dodatna presjecišta koja predstavljaju daljnja raščlanjenja glavnoga kriterija u podkriterije. Svako presjecište se može razgranati u najviše sedam presjecišta u sljedećoj nižoj razini itd. Expert Choice je sposoban modelirati složene probleme koje se sastoje i od tisuću presjecišta. [12]

### 6.4.1. Model View

Nakon pokretanja EC-a otvara se Model View prozor koji se sastoji od tri okna (Slika 6.1):

- U lijevom oknu je Tree View prikaz s čvorovima, ciljem, kriterijima i podkriterijima
- U desnom gore oknu je prikaz alternativa
- U desnom donjem oknu je dokument s informacijama za čvor i/ili alternative

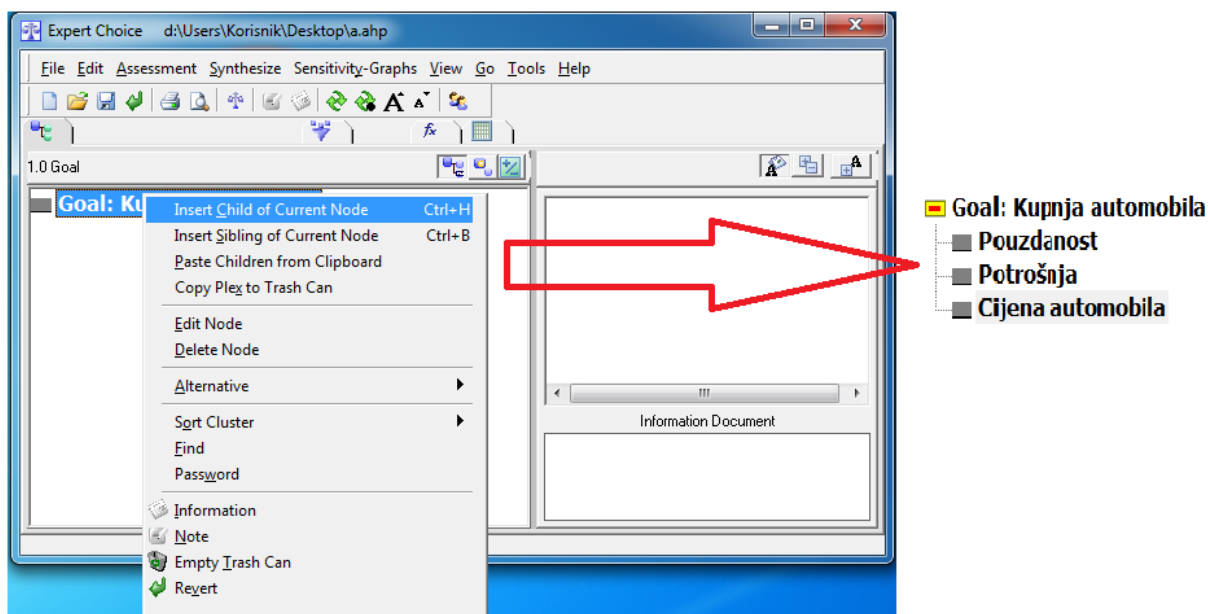


Slika 6.1 Model View prozor

### 6.4.2. Izrada novog modela

Radi lakšeg objašnjenja procesa izrade modela u softveru EC, za primjer je postavljen imaginarni problem donošenja odluke o kupnji automobila, koji ujedno predstavlja i zadani cilj. Kao opcije nude se tri alternative: *Ford Focus*, *Opel Corsa* i *VW Golf VI*. Kriteriji po kojima se odabire automobil su: *Pouzdanost*, *Potrošnja* i *Cijena automobila*. U nastavku je prikaz osnovnih koraka izrade tog modela:

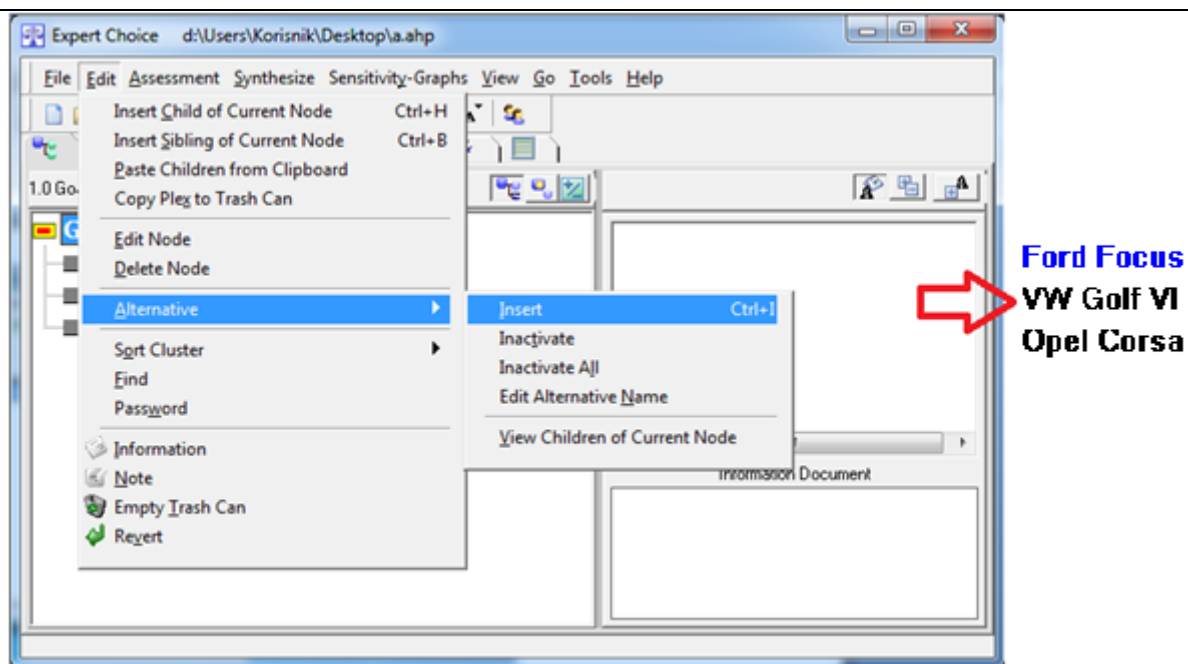
1. Prvo što se čini, nakon pokretanja EC-a, upisuje se ime modela (*Open > New Model > File Name*). Nakon čega slijedi unos zadanog cilja (*Enter a description for your goal*).
2. Sljedeći korak je unos kriterija u *Tree View* okno. To se može izvesti na dva načina. Prvi način je pritiskom desne tipke miša na *Goal* i odabirom *Insert Child of the Current Node*, a drugi odlaskom na *Edit > Insert Child of the Current Node* i unese se prvi kriterij (Slika 6.2). Isti postupak se ponavlja sve do posljednjeg unosa. Ako se želi unijeti podkriterij, odabire se čvor željenog kriterija te se maloprije opisani postupak ponovi.



Slika 6.2 Unos kriterija


3. Nakon unosa kriterija vrši se unos alternativa. To se također može izvesti na dva načina. Prvi je pritiskom desne tipke miša na okno alternativa te odabirom na *Insert*, a drugi odlaskom na *Edit > Alternative > Insert* (Slika 6.3)





Slika 6.3 Unos alternativa

4. Zadnji korak u izradi novog modela je unos informacija o cilju, kriterijima, podkriterijima i alternativama u okno za informacije. I ovdje je moguć unos na dva načina. Prvi, označavanjem željenog čvora i pritiskom lijeve tipke miša na okno za informacije, dok je drugi, označavanjem željenog čvora pa se odabere *Edit > Information* (Slika 6.4).



Slika 6.4 Unos informacija

### 6.4.3. *Donošenje parnih prosudbi*

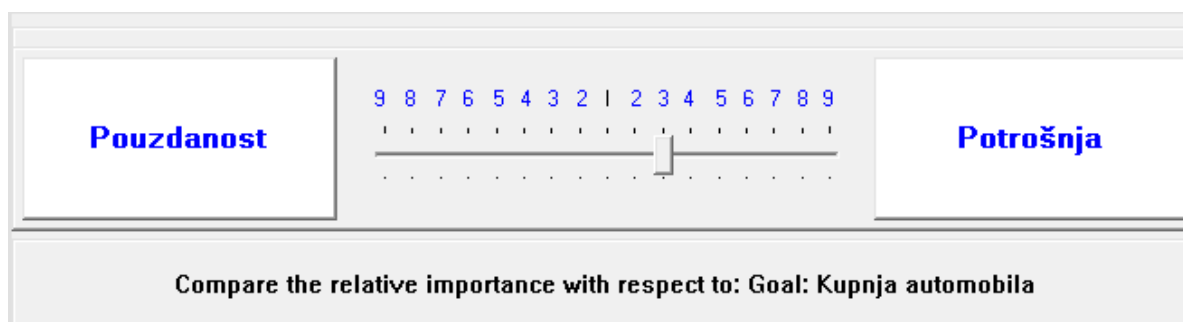
Nakon što je izgrađen model, sljedeći korak je vrednovanje elemenata parnom komparacijom. Parna komparacija je proces usporedbe relativnih važnosti, sklonosti ili vjerojatnost dvaju elemenata u odnosu na element koji se nalazi na razini iznad. Donositelj odluke parnom komparacijom kroz cijeli model uspostavlja prioritete. Postoje tri načina parnih komparacija u EC-u i to su:

- numerička,
- grafička,
- i verbalna komparacija. [22]

#### 6.4.3.1. *Numerička komparacija*

Numerička komparacija poželjna je kod uspoređivanja svojstava koja se daju prosuditi u brojčanom razmjeru. U numeričkoj skali, 1.0 znači da su elementi koji se uspoređuju jednako važni, 2.0 da je jedan element dvostruko važniji od drugog i 9.0 da je jedan element devet puta važniji od drugog. To su apsolutne brojke koje nam govore, npr. koji od dva kamena je teži i koliko puta teži. Dakle, numerička prosudba 5.0 znači da je jedan kamen pet puta teži od drugog kamena. Ako je razlika između elemenata toliko velika da nisu istog reda veličine, odnosno neki elementi skupine su više od devet puta važniji od nekih drugih elemenata iz skupine, oni bi trebali biti stavljani u nakupine takvih elemenata. Druga alternativa je proširenje numeričke skale, koju dozvoljava EC, na omjer 99:1. No ljudi nisu točni u izradi prosudbe kada se elementi razlikuju po omjeru 10:1 ili više. [20]

Slika 6.5 prikazuje numeričku skalu u programu EC.



**Slika 6.5 Numerička skala**

#### 6.4.3.2. Grafička komparacija

Grafička skala za parno uspoređivanje može biti korištena za izražavanje odnosa između dvaju elemenata kao omjer dužina dviju linija. Presude se unose u grafički mod povlačenjem i podešavanjem relativnih dužina dviju linija, gdje svaka linija predstavlja jedan element u parnoj usporedbi (Slika 6.6). [20]




Slika 6.6 Grafička skala

#### 6.4.3.3. Verbalna komparacija

Numeričke i grafičke prosudbe se donose u omjerima dvaju elemenata, te stoga posjeduju razinu omjera mjerenja, dok za verbalnu skalu to ne vrijedi. Verbalna skala zapravo je uobičajena skala. Kada donositelj odluke prosuđuje da je A puno važnije od B, zna se da je A važnije od B, ali ne zna se koliki je njihov interval ili omjer. Studije su pokazale da relativne (parne) verbalne prosudbe mogu proizvesti točne uobičajene prosudbe, pod uvjetom da su redundantne (nepotrebne) presude uključene u izračun. Redundancija pomaže pri smanjivanju prosječnog efekta pogrešaka analogno načinu uzimanja prosjeka uzorka mjerenja, koji će proizvesti procjenu koja će biti bliža stvarnoj sredini, nego što će to biti samo od jednog suda. Osim smanjivanja utjecaja uobičajenih vrsta grešaka u mjerenju, ovaj postupak također smanjuje utjecaj nejasnoće skale i razliku u interpretaciji skale od različitih donositelja odluke. Dok relativne parne prosudbe mogu biti donesene numerički ili grafički, verbalne prosudbe su važne u donošenju odluka zato što su bliskije ljudima, te su ljudi naučili koristiti riječi za mjerenje intenziteta osjećaja. Npr. ugodnije je tvrditi da je jedan voćni okus umjereno slađi od drugog, nego tvrditi da je jedan voćni okus tri puta slađi od drugog. [20]

Slika 6.7 prikazuje verbalnu skalu u programu EC.

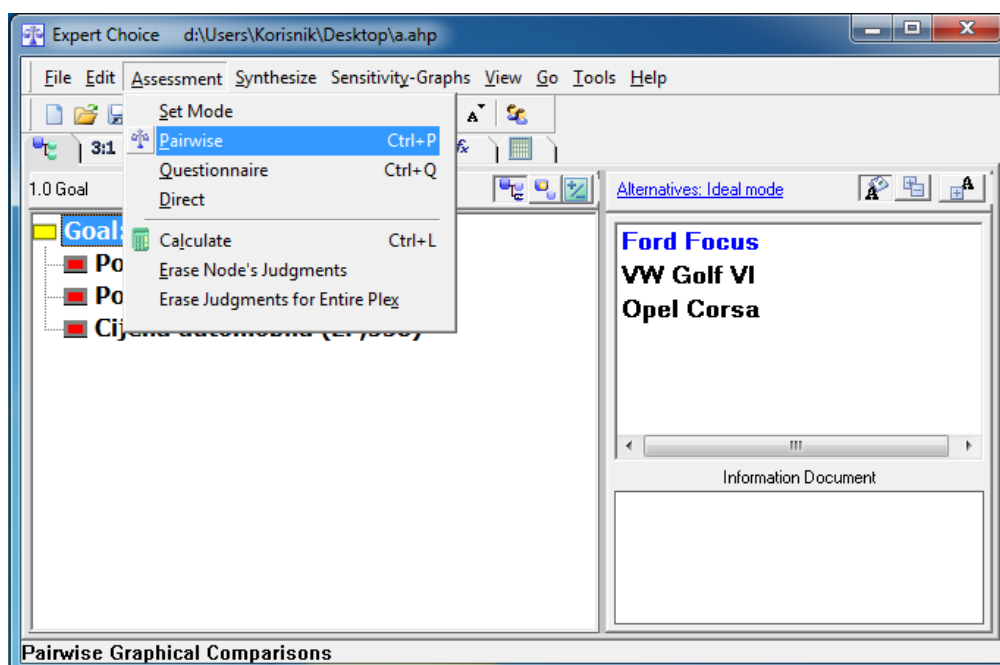


Slika 6.7 Verbalna skala

#### 6.4.3.4. Usporedba kriterija i alternativa verbalnom komparacijom

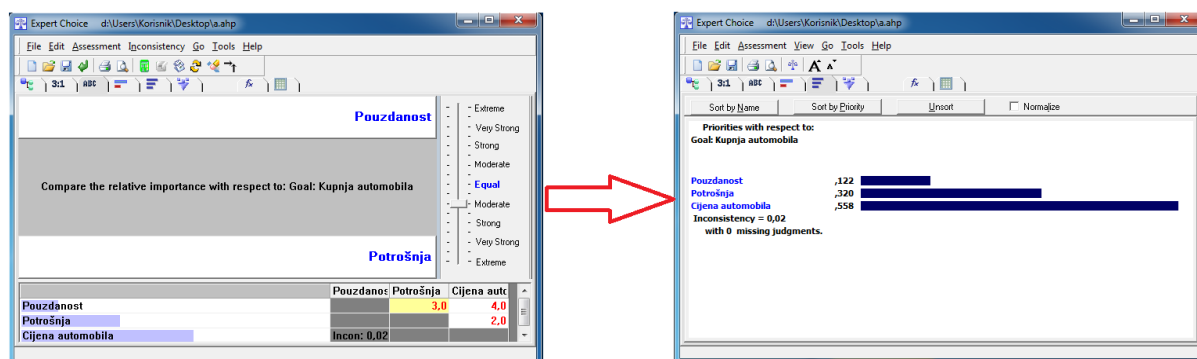
Nad odabranim kriterijima i alternativama iz poglavlja 6.4.2. ovoga rada prema ispod navedenim *koracima* vrši se usporedba kriterija i alternativa:

1. Prvo se donosi prosudba o važnosti kriterija međusobnom usporedbom dvaju kriterija s obzirom na zadani cilj. Odabere se lijevom tipkom miša cilj pa se zatim pritisne iz izbornika *Assessment > Pairwise* (Slika 6.8). Po defaultu otvorit će se verbalna komparacija.



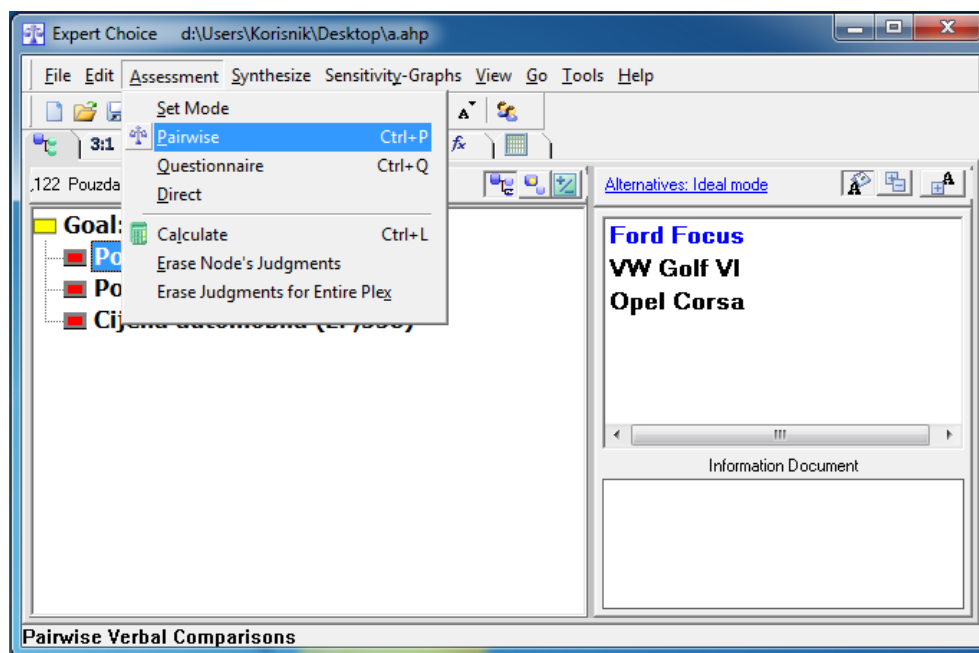
Slika 6.8 Odabir komparacije kriterija

2. Povlačenjem indikatora verbalne skale prema gore ili dolje na odgovarajući položaj odabire se prosudba koja najbolje opisuje preferenciju. Postupak se ponavlja dok se ne izvrše sve međusobne usporede svih kriterija u modelu u odnosu na željeni cilj. Nakon što su napravljene sve prosudbe, automatski se pojavljuje naredba *Record judgements and calculate*. Potvrdom ove naredbe izračunat je prioritet kriterija. Slika 6.9 prikazuje postupak parne verbalne usporedbe kriterija *Pouzdanosti* i *Potrošnje*, te rezultate komparacije svih kriterija. Na dnu slike može se vidjeti nekonzistentnost od 2% koja je ispod 10%, što ukazuje da je model prioriteta kriterija dobro strukturiran.



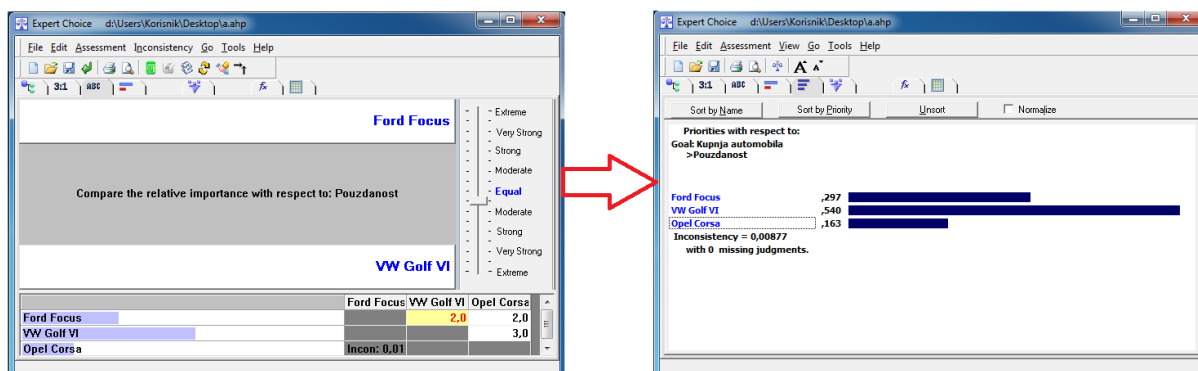
Slika 6.9 Rezultati parne komparacije kriterija

3. Nakon provedbe komparacija kriterija vrše se usporedbe alternativa prema zadanim kriterijima. Lijevom tipkom miša klikne se na prvi kriterij u strukturi te se iz izbornika odabere *Assessment > Pairwise* (Slika 6.10).




Slika 6.10 Odabir komparacije alternativa

4. Postupak usporedbe alternativa sličan je postupku usporedbe kriterija, samo što se sada alternative uspoređuju u odnosu na svaki kriterij. Slika 6.11 prikazuje postupak parne verbalne usporedbe dviju alternativa *Ford Focus* i *VW Golf VI* u odnosu na kriterij *Pouzdanost*, te rezultate parne komparacije alternativa s obzirom na taj kriterij.



Slika 6.11 Rezultati parne komparacije alternativa

5. Nakon što su učinjene sve prosudbe u modelu i izračunati prioriteti, izvodi se sinteza rezultata. Kada se vrati nazad u *Model View*, prioriteti alternativa vidljivi su u oknu alternativa, a prioriteti kriterija u *Tree View*. Sa Slike 6.12 vidljivo je da je najprikladnija alternativa *Opel Corsa*, a najutjecajniji kriterij *Cijena automobila*.



Slika 6.12 Sinteza rezultata

---

#### 6.4.3.5. Provođenje osjetljivosti pomoću Expert Choice-a

Posljednji korak procesa odlučivanja je analiza osjetljivosti koja se temelji na vizualizaciji posljedica promjena ulaznih podataka. Ulazni podaci za model pomoću kojih se izračunaju prioriteti su procjene relativnih važnosti kriterija i procjena omjera lokalnih prioriteta alternativa. Te procjene mogu varirati u nekim rasponima, a da te promjene još uvijek budu u skladu s preferencijama donositelja odluke. Analiza osjetljivosti provodi se s ciljem da se vidi u kojoj mjeri se promjene ulaznih podataka odražavaju na ukupne prioritete alternativa. Da bi se došlo do zaključka da li je rang lista alternativa dovoljno stabilna u odnosu na prihvatljive promjene ulaznih podataka treba izračunati prioritete alternativa za brojne različite kombinacije ulaznih podataka.

Postoji 5 različitih vrsta analiza osjetljivosti:

1. Dynamic,
2. Gradient,
3. Performance,
4. Head to Head i
5. 2D.


Moguće je otvoriti 4 vrste analiza osjetljivosti odjednom ili svaku vrstu posebno. Svaki grafički prikaz ima svoj vlastiti meni s naredbama i svaka analiza osjetljivosti može biti uspoređena sa *što-ako* analizom budući da su promjene koje se rade u grafičkom prikazu privremene. [23]

U nastavku će biti prikazano kako se analiza osjetljivosti može provesti na kvalitetan i razumljiv način uz pomoć softvera EC.

##### 6.4.3.5.1. Opcija Gradient

Gradient prikaz predoduje kako promjene težina pojedinih kriterija utječu na prioritete alternativa. [23]

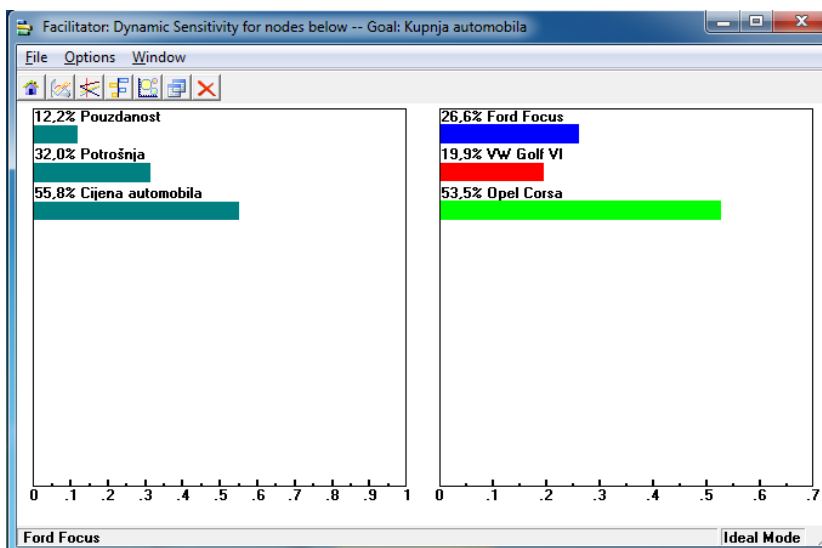
Na Slici 6.13 prikazana je osjetljivost prioriteta alternativa s obzirom na promjene kriterija *Pouzdanost*. Može se primijetiti da prioritet *VW Golf VI* raste s porastom težine promatranog kriterija, prioritet *Opel Corsa* opada, dok na prioritet *Ford Focus* relativno malo utječe promjena težine kriterija.



Slika 6.13 Gradient prikaz


## 6.4.3.5.2. Opcija Dynamic

Opcija Dynamic omogućava dinamički grafički prikaz uvida u to kako se dinamički mijenjaju prioritete alternativa ukoliko se mijenjaju težine pojedinih kriterija. Jednostavnim povlačenjem miša lijevo ili desno, smanjuje se ili povećava važnost određenog kriterija, dok se težine ostalih kriterija proporcionalno mijenjaju u odnosu na početne težine kriterija. [23] Kako se ta promjena težina kriterija odražava na prioritete alternativa moguće je vidjeti na desnoj strani grafičkog prikaza na Slici 6.14 i Slici 6.15.



Slika 6.14 Dynamic prikaz - početni problem






**Slika 6.15** Dynamic prikaz - izmijenjeni problem

Dynamic prikaz ima i opciju Components u kojoj je moguće vidjeti udjele težina pojedinih kriterija u ukupnom prioritetu alternativa. [23]

Pomoću opcije Components mogu se dobiti odgovori na pitanja poput: „Kolika bi trebala biti težina kriterija *Pouzdanost* da automobil *VW Golf VI* bude prijedlog za najbolju alternativu, a automobil *Opel Corsa* za najlošiju alternativu i to značajno najlošiju alternativu (Slika 6.16).

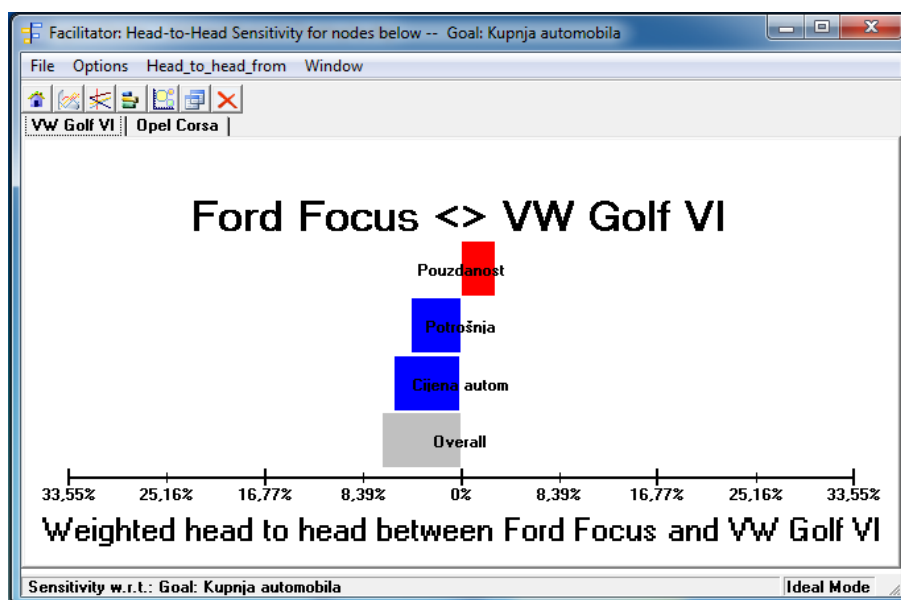


**Slika 6.16** Dynamic - Components prikaz

#### 6.4.3.5.3. Opcija Head to Head

U Head to Head opciji analize osjetljivosti moguće je jednostavnim korištenjem miša vizualizirati odnose razmatranih alternativa u svim parovima na način da međusobni kvalitativni odnos dvije alternative bude prikazan pravokutnim površinama. Informacije o tome koja je alternativa bolja, predstavljena je prostornom pozicijom pravokutnika. [23]

Na Slici 6.17 prikazan je odnos između alternativa *Ford Focus* i *VW Golf VI*. Kriteriji po kojima ima prednost alternativa *Ford Focus* pridruženi su joj pravokutnici odgovarajućih površina usmjereni ulijevo (kriteriji *Potrošnja* i *Cijena automobila*), a pravokutnici pridruženi kriterijima po kojima ima prednost alternativa *VW Golf VI* orijentirani su udesno. Ukupna prednost jedne alternative u odnosu na drugu prikazana je pravokutnikom na najnižoj razini. Budući da je pravokutnik orijentiran ulijevo, ukupnu prednost u ovoj kombinaciji promatranih alternativa ima alternativa *Ford Focus*.



Slika 6.17 Head to Head grafikon


#### 6.4.3.5.4. Opcija Performance

Opcija Performance omogućava prikaz utjecaja pojedinih težina kriterija na poredak alternativa. Razlikuju se:

- trenutni poredak alternativa - predstavlja promjenu prioriteta alternative pod utjecajem težine jednog kriterija
- ukupni poredak alternativa - predstavlja poredak alternativa pod utjecajem težina svih kriterija [23]

Sa Slike 6.18 vidljive su sljedeće stvari:

- na desnoj strani y-osi prikazani su prioriteti alternativa i redoslijed alternativa - može se uočiti da je najbolja alternativa *Opel Corsa*, a najgora *VW Golf VI*
- na x-osi prikazani su kriteriji i njihov utjecaj na pojedinu alternativu - može se vidjeti da kriteriji koji negativno utječu na alternativu *VW Golf VI* su *Potrošnja* i *Cijena automobila*, dok je prema kriteriju *Pouzdanost* na prvom mjestu u poretku alternativa
- težine pojedinih kriterija prikazane su na lijevoj strani y-osi




Slika 6.18 Performance grafikon

#### 6.4.3.5.5. Opcija 2D

U 2D opciji analize osjetljivosti prikazani su prioriteti alternativa s obzirom na dva kriterija koja se uspoređuju. Moguće je analizirati prioritete alternativa pri bilo kojoj kombinaciji dva kriterija. Područje 2D grafikona je podijeljeno na 4 kvadranta. [23]

Na Slici 6.19 prikazani su prioriteti alternativa kada se u odnos stave kriteriji *Pouzdanost* i *Potrošnja*.



Slika 6.19 2D grafikon

## 7. ODABIR PRIMARNOG PROCESA POMOĆU EXPERT CHOICE

U ovome poglavlju je prikazana i objašnjena primjena AHP metode za konkretan izradak primjenom alata Expert Choice 11.


Prije primjene AHP metode potrebno je upozoriti da je potrebno široko i duboko ekspertno znanje pojedinih tehnologija. Dakle, za strateško promišljanje načina izrade kompliciranijih izradaka ili kod projektiranja novog proizvodnog sustava široke palete asortimana proizvoda (reprezentanti za grupne tehnologije), potrebno je imati konkretne podatke koji se tiču cijena alata i opreme, produktivnosti, cijena po satu, razina automatiziranosti ljevaonice i kovačnice (to utječe na cijenu odljevka/otkovka i rokove isporuke kooperanata), te razine automatiziranosti OOČ (tip obradnog centra, broj osi, broj protuvretena, broj paleta, količina proizvoda po stupiću na paleti, broj alata u revolveru, automatska izmjena alata, automatizirana dobava šipki, manipulacija obratkom ručna ili uz pomoć robota).

Važno je naglasiti da su podaci za primjenu Expert Choicea crpljeni iz dosadašnjeg znanja i raznih literatura zbog nemogućnosti dobivanja relevantnih podataka iz industrije jer često predstavljaju tehnološku i poslovnu tajnu. Dakle, prisutna je subjektivnost kod procjene težina podkriterija, kriterija i alternativa.

### 7.1. Proizvod i njegove značajke

Dogovoreno je da će se odabir primarnog procesa vršiti za izradak *Glavina* koji je prikazan na Slici 7.1. Odabran je proizvod kojega je moguće kovati, lijevati i obrađivati obradom odvajanja čestice. Radionički crtež izratka je dan u Prilogu I.

Odabir primarnog procesa obavljat će se za dvije različite količine serija proizvoda. Jedna količina će iznositi 50 000 komada, a druga 2 000 komada s tim da je svaka serija neovisna o drugoj. Odabrane su dvije različite količine proizvoda kako bi se prikazao utjecaj količine proizvoda na odabir primarnog procesa.



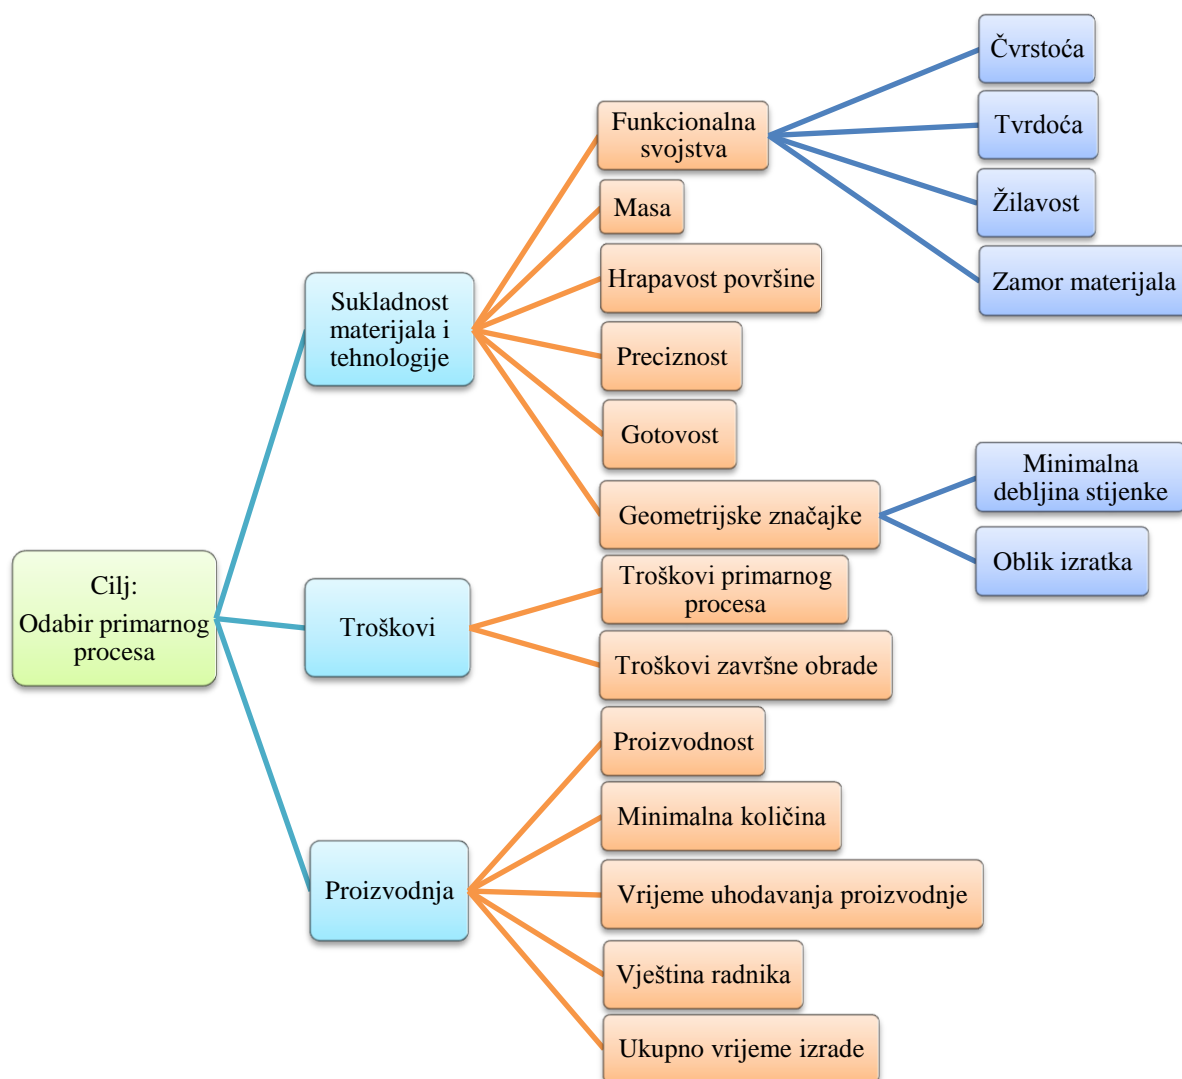
Slika 7.1 Glavina

Značajke proizvoda:

- Materijal: Č1590.5 - nelegirani čelik
- Masa: 0,250 kg
- Minimalna debljina stijenke: 7 mm
- Najzahtjevnija kvaliteta površine: Ra 1,6  $\mu\text{m}$  (ostalo Ra 12,5  $\mu\text{m}$ )


## 7.2. Hijerarhijska struktura za odabir primarnog procesa

Za zadani izradak potrebno je odabrati primarni proces koji najbolje odgovara tehnološkim i ekonomskim zahtjevima izrade, prema kriterijima koje je potrebno definirati. Na Slici 7.2 prikazana je hijerarhijska struktura postavljenog problema s krajnjim ciljem te definiranim kriterijima i podkriterijima.



Slika 7.2 Hijerarhijska struktura odabira primarnog procesa

Na Slici 7.3 prikazan je postavljeni problem u Model View prozora softvera EC 11. Na lijevoj strani Model View prozora prikazan je cilj zadanog problema s definiranim kriterijima i podkriterijima, a na desnoj strani su ponuđene alternative, odnosno proizvodne tehnologije. Definirani kriteriji i podkriteriji pojašnjeni su u poglavlju 3., a odabrane proizvodne tehnologije u poglavlju 7.3. ovoga rada.



**Slika 7.3 Model View prikaz odabira primarnog procesa za izradak Glavina**

### **7.2.1. Ponderiranje kriterija za odabir primarnog procesa**

Nakon definiranja hijerarhijske strukture, slijedi procjena i rangiranje kriterija i podkriterija, odnosno dodjeljivanje težine kriterijima i podkriterijima.

Ponderiranje kriterija započinje od najniže razine podkriterija koji se uspoređuju u odnosu na nadređeni podkriterij ili kriterij, pa prema kriterijima koji se uspoređuju u odnosu na cilj.

Podkriteriji i kriteriji su procijenjeni postupkom parne usporedbe svih podkriterija i kriterija, gdje je korištena numerička skala prilikom procjene uz primjenu opcije *Questionnaire*.

Bitno je zapamtiti da procjena prioriteta kriterija vrijedi za oba slučaja odabira primarnog procesa, odnosno za veličinu serije od 50 000 komada i za veličinu serije od 2 000 komada.

#### **Procjena težine podkriterija u odnosu na podkriterij Funkcionalna svojstva**

Podkriteriji su međusobno uspoređivani u parovima (Slika 7.4), gdje sivo označeni brojevi označavaju važnost jednog podkriterija u odnosu na drugi. Slika prikazuje i sintezu rezultata s konačnim poretom podkriterija prema njihovim težinama, iz čega je vidljivo da su *Čvrstoća* i *Žilavost* dva najvažnija podkriterija.

1	Čvrstoća	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Tvrdoća
2	Čvrstoća	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Žilavost
3	Čvrstoća	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Zamor materijala
4	Tvrdoća	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Žilavost
5	Tvrdoća	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Zamor materijala
6	Žilavost	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Zamor materijala



**Slika 7.4 Procjena i sinteza rezultata podkriterija u odnosu na podkriterij Funkcionalna svojstva**

### Procjena težine podkriterija u odnosu na podkriterij Geometrijske značajke

Postupkom parne usporedbe dvaju podkriterija u odnosu na podkriterij *Geometrijske značajke* dobiveni su rezultati (Slika 7.5) prema kojima podkriterij *Oblik izratka* ima prednost u odnosu na podkriterij *Minimalna debljina stijenke*.

1	Minimalna debljina stije	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Oblik izratka
---	--------------------------	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---------------



**Slika 7.5 Procjena i sinteza rezultata podkriterija u odnosu na podkriterij Geometrijske značajke**

### Procjena težine podkriterija u odnosu na kriterij Sukladnost materijala i tehnologije

Postupkom parne usporedbe svih podkriterija u odnosu na kriterij *Sukladnost materijala i tehnologije* dobiveni su rezultati (Slika 7.6) prema kojima podkriteriji *Preciznost* i *Gotovost* imaju prednost u odnosu na ostale podkriterije.


1	Funkcionalna svojst	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Masa
2	Funkcionalna svojst	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Hrapavost površine
3	Funkcionalna svojst	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Preciznost
4	Funkcionalna svojst	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Gotovost
5	Funkcionalna svojst	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Geometrijske značaj
6	Masa	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Hrapavost površine
7	Masa	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Preciznost
8	Masa	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Gotovost
9	Masa	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Geometrijske značaj
10	Hrapavost površine	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Preciznost
11	Hrapavost površine	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Gotovost
12	Hrapavost površine	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Geometrijske značaj
13	Preciznost	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Gotovost
14	Preciznost	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Geometrijske značaj
15	Gotovost	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Geometrijske značaj



**Slika 7.6 Procjena i sinteza rezultata podkriterija u odnosu na kriterij Sukladnost materijala i tehnologije**

### Procjena težine podkriterija u odnosu na kriterij Troškovi


Postupkom parne usporedbe dvaju podkriterija *Troškovi primarnog procesa* i *Troškovi završne obrade* u odnosu na kriterij *Troškovi* dobiveni su rezultati (Slika 7.7) prema kojima prednost ima podkriterij *Troškovi primarnog procesa*.



Slika 7.7 Procjena i sinteza rezultata podkriterija u odnosu na kriterij Troškovi

### Procjena težine podkriterija u odnosu na kriterij Proizvodnja

Postupkom parne usporedbe svih podkriterija u odnosu na kriterij *Proizvodnja* dobiveni su rezultati koji su vidljivi na Slici 7.8. Vidljivo je da je podkriterij *Minimalna količina* najutjecajniji podkriterij, te slijede Proizvodnost i Ukupno vrijeme izrade.




Slika 7.8 Procjena i sinteza rezultata podkriterija u odnosu na kriterij Proizvodnja

### Procjena težina kriterija u odnosu na Cilj: Odabir primarnog procesa

Nakon što je završena usporedba podkriterija u odnosu na nadređene podkriterije i kriterije, vrši se usporedba kriterija u odnosu na *Cilj: Odabir primarnog procesa*.

Pošto je uzet za analizu odabira primarnog procesa takav izradak koji je moguće izraditi postupkom lijevanja, kovanja i obradom odvajanja čestica, kao najvažniji kriteriji razmatraju se *Troškovi* i *Proizvodnja* (Slika 7.9). Inače bi najutjecajniji kriterij bio *Sukladnost materijala i tehnologije*. Jer taj kriterij eliminira mnoštvo tehnologija ukoliko nema sukladnosti vrste materijala i tehnologije.

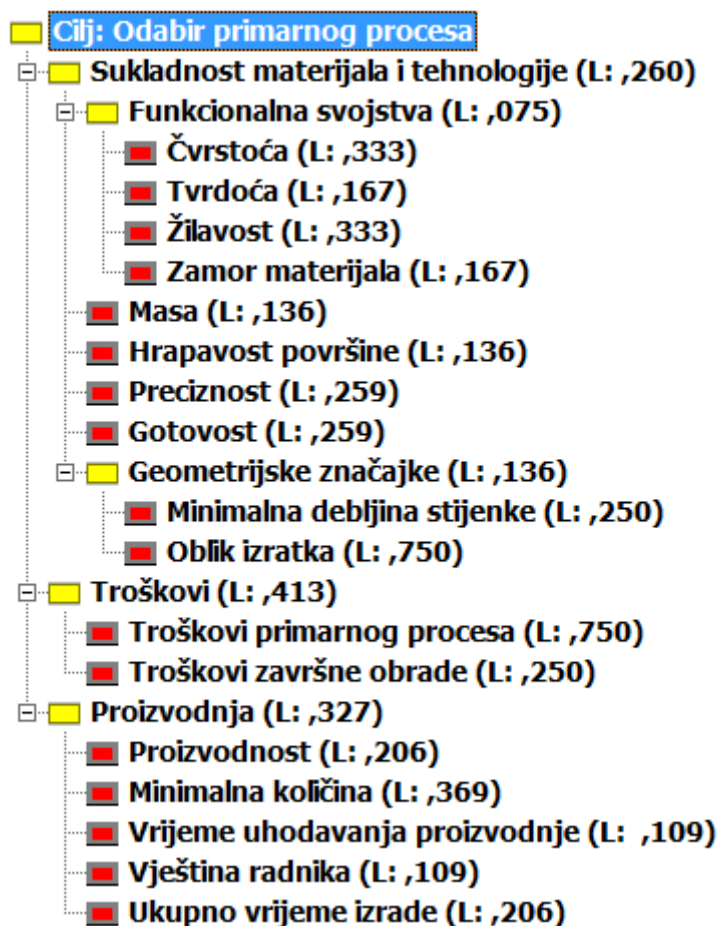




**Slika 7.9** Procjena i sinteza rezultata kriterija u odnosu na Cilj: Odabir primarnog procesa

### 7.2.2. Prikaz prioriteta kriterija i podkriterija u Tree View oknu

U nastavku je prikaz prioriteta kriterija i podkriterija u Tree View oknu softvera Expert Choice 11 (Slika 7.10). Brojevi u zagradama predstavljaju težine pojedinih kriterija i podkriterija u odnosu na nadređene podkriterije, kriterije te cilj. Zbroj brojeva u zagradama jednak je 1, što predstavlja 100%.



**Slika 7.10** Prikaz prioriteta kriterija i podkriterija

---

### 7.3. Odabir najbolje alternative

Nakon što su definirani kriteriji i podkriteriji te njihovi prioriteti, slijedi usporedba alternativa za svaki od kriterija i podkriterija. Alternative, odnosno proizvodne tehnologije, koje se razmatraju u ovom cilju odabira primarnog procesa su:

- Lijevanje u pijesku
- Precizni lijev
- Kovanje u zatvorenom ukovnju
- Kovanje u otvorenom ukovnju
- Obrada odvajanjem čestica (OOČ)

ASM nudi više različitih tehnologija za zadani materijal kao što su: lijevanje u pijesku, precizno lijevanje, istiskivanje, hladno sabijanje, kovanje u zatvorenom ukovnju, kovanje u otvorenom ukovnju, prešanje i sinteriranje, topla ekstruzija, OOČ iz sirovca i slično. Tehnologije koje su sukladne sa zadanim materijalom prikazane su u Prilogu II.

U razmatranje su se mogle uzeti i nekonvencionalne tehnologije, kao što su aditivne tehnologije, ali u ovome radu uzete su samo određene konvencionalne tehnologije i to one za koje su pronađeni podaci i koje zadovoljavaju funkcionalna svojstva te produktivnost. Izbacivanje, odnosno ne uzimanje u obzir ostalih alternativa kod odabira primarnog procesa vršilo se i na temelju znanja, iskustva i logike.

#### 7.3.1. Ponderiranje najbolje alternativa


Alternative su procijenjene postupkom parne usporedbe u odnosu na zadane podkriterije i kriterije, gdje je korištena numerička skala prilikom procjene.

Podaci korišteni kod usporedbi alternativa nalaze se u Prilogu III, Prilogu IV i Prilogu V.

##### 7.3.1.1. Procjena za veličinu serije od 50 000 komada

#### **Procjena alternativa prema podkriteriju Funkcionalna svojstva**

Usporedbom alternativa s obzirom na podkriterije *Čvrstoća*, *Tvrdoća*, *Žilavost* i *Zamor materijala* dobiveni su rezultati na Slici 7.11. Poredak alternativa je prema prioritetu, gdje decimalni brojevi predstavljaju težinu pojedinih alternativa u odnosu na zadani podkriterij.




**Slika 7.11 Rezultati procjene alternativa u odnosu na podkriterij Funkcionalna svojstva**

### Procjena alternativa prema podkriteriju Masa

Usporedba alternativa prema podkriteriju *Masa* odnosi se na to da li se promatranom tehnologijom može izraditi željeni izradak željene mase. Masa izratka *Glavine* iznosi 0,25 kg. Pošto sve tehnologije zadovoljavaju ovaj podkriterij nije dan grafički prikaz rezultata kriterija.

### Procjena alternativa prema podkriteriju Hrapavost površine


Usporedba alternativa prema podkriteriju *Hrapavost površine* odnosi se na to da li se promatranom tehnologijom može dobiti tražena hrapavost površine. U slučaju izratka glavine najzahtjevnija hrapavost površine iznosi Ra 1,6 μm. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.12.



**Slika 7.12 Rezultati procjene alternativa u odnosu na podkriterij Hrapavost površine**

### Procjena alternativa prema podkriteriju Preciznost


Usporedba alternativa prema podkriteriju *Preciznost* odnosi se na to koliko se precizno mogu dobiti tražene tolerancije dimenzija i oblika. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.13.



**Slika 7.13 Rezultati procjene alternativa u odnosu na podkriterij Preciznost**

### **Procjena alternativa prema podkriteriju Gotovost**

Pod pojmom gotovosti misli se na dobivanje izratka koji je što sličniji krajnjem proizvodu („near net shape“) i prednost se daje alternativama koje što više zadovoljavaju definiciju tog kriterija. Slika 7.14 prikazuje rezultate procjene alternativa u odnosu na kriterij *Gotovost*, iz čega je vidljivo da prioritet ima alternativa OOČ.




**Slika 7.14** Rezultati procjene alternativa u odnosu na podkriterij *Gotovost*

### **Procjena alternativa prema podkriteriju Geometrijske značajke**

Procjena alternativa prema podkriteriju *Geometrijske značajke* podrazumijeva dobivanje oblika izratka sličnog obliku željenog proizvoda. Podkriterij *Geometrijske značajke* podijeljen je na podkriterije *Oblik izratka* i *Minimalna debljina stijenke*. Kako sve tehnologije zadovoljavaju dane kriterije, rezultati nisu prikazani.

### **Procjena alternativa prema podkriteriju Troškovi primarnog procesa**

Usporedba alternativa prema podkriteriju *Troškovi primarnog procesa* odnosi se na to koliko iznose ukupni troškovi primarnog procesa. Ukupni troškovi primarnog procesa sastoje se od troškova rada, materijala, alata i opreme. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.15. Alternative su uspoređivane prema minimumu troškova.



**Slika 7.15** Rezultati procjene alternativa u odnosu na podkriterij *Troškovi primarnog procesa*

### **Procjena alternativa prema podkriteriju Troškovi završne obrade**


Usporedba alternativa prema podkriteriju *Troškovi završne obrade* odnosi se na to koliko će iznositi ukupni troškovi završne obrade, što uključuje troškove rada, opreme i alata. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.16. Alternative su

uspoređivane prema minimumu troškova. Podaci koji su korišteni kod ove usporedbe nalaze se u Prilogu III i prilogu IV, s tim da su se gledali najniži troškovi završne obrade pošto je izradak jednostavan i ne previše zahtjevan.




**Slika 7.16** Rezultati procjene alternativa u odnosu na podkriterij Troškovi završne obrade  
**Procjena alternativa prema podkriteriju Proizvodnost**

Usporedba alternativa prema podkriteriju *Proizvodnost* odnosi se na to kolika je proizvodnost pojedine tehnologije, odnosno koliki broj komada je moguće proizvesti po kalupu, alatu ili satu. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.17.



**Slika 7.17** Rezultati procjene alternativa u odnosu na podkriterij Proizvodnost  
**Procjena alternativa prema podkriteriju Minimalna količina**


Usporedba alternativa prema podkriteriju *Minimalna količina* odnosi se na to kolika je minimalna količina proizvoda za koju se isplati koristiti pojedina tehnologija. Rezultati procjena alternativa prema zadanome podkriteriju dani su na Slici 7.18.



**Slika 7.18** Rezultati procjene alternativa u odnosu na podkriterij Minimalna količina

### **Procjena alternativa prema podkriteriju Vrijeme uhodavanja proizvodnje**


Usporedba alternativa prema podkriteriju *Vrijeme uhodavanja* odnosi se na to koliko je potrebno vrijeme za uhodavanje proizvodnje za svaku od alternativa. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.19.



**Slika 7.19** Rezultati procjene alternativa u odnosu na podkriterij Vrijeme uhodavanja proizvodnje

### **Procjena alternativa prema podkriteriju Vještina radnika**


Usporedba alternativa prema podkriteriju *Vještina radnika* odnosi se na to koliko je potrebna vještina radnika za rad na svakoj od proizvodnih tehnologija. Poželjna je niskokvalificirana radna snaga jer se tako štedi na plaćama. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.20.



**Slika 7.20** Rezultati procjene alternativa u odnosu na podkriterij Vještina radnika

### **Procjena alternativa prema podkriteriju Ukupno vrijeme izrade**

Usporedba alternativa prema podkriteriju *Ukupno vrijeme izrade* odnosi se na to koliko je potrebno vrijeme da se izradi cijela serija proizvoda. Ukupno vrijeme izrade procijenjeno je prema količini proizvoda, potrebnoj završnoj obradi, odabranoj tehnologiji te produktivnosti pojedine tehnologije. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.21.



**Slika 7.21** Rezultati procjene alternativa u odnosu na podkriterij Ukupno vrijeme izrade

#### 7.3.1.2. Procjena za veličinu serije od 2 000 komada


Procjena alternativa za veličinu serije od 2 000 komada vrši se za samo kriterije:

- Troškovi primarnog procesa
- Troškovi završne obrade
- Minimalna količina
- Ukupno vrijeme izrade

Dok za ostale kriterije poredak alternativa ostaje isti jer na njih ne utječe promjena veličine serije.

#### **Procjena alternativa prema podkriteriju Troškovi primarnog procesa**

Rezultati procjena alternativa prema zadanom podkriteriju za veličinu serije od 2 000 komada dani su na Slici 7.22. Alternative su uspoređivane prema minimumu troškova.



**Slika 7.22** Rezultati procjene alternativa u odnosu na podkriterij Troškovi primarnog procesa


#### **Procjena alternativa prema podkriteriju Troškovi završne obrade**

Rezultati procjena alternativa prema zadanom podkriteriju za veličinu serije od 2 000 komada dani su na Slici 7.23. Alternative su uspoređivane prema minimumu troškova. Sa slike je vidljivo da prioritet ima OOČ.




**Slika 7.23** Rezultati procjene alternativa u odnosu na podkriterij Troškovi završne obrade  
**Procjena alternativa prema podkriteriju Minimalna količina**

Rezultati parne procjene alternativa prema zadanom podkriteriju i prema zadanoj količini proizvoda dani su na Slici 7.24.



**Slika 7.24** Rezultati procjene alternativa u odnosu na podkriterij Minimalna količina  
**Procjena alternativa prema podkriteriju Ukupno vrijeme izrade**

Ukupno vrijeme izrade procijenjeno je prema veličini serije od 2 000 komada, potrebnoj završnoj obradi, odabranoj tehnologiji te produktivnosti te tehnologije. Rezultati procjena alternativa prema zadanom podkriteriju dani su na Slici 7.25.

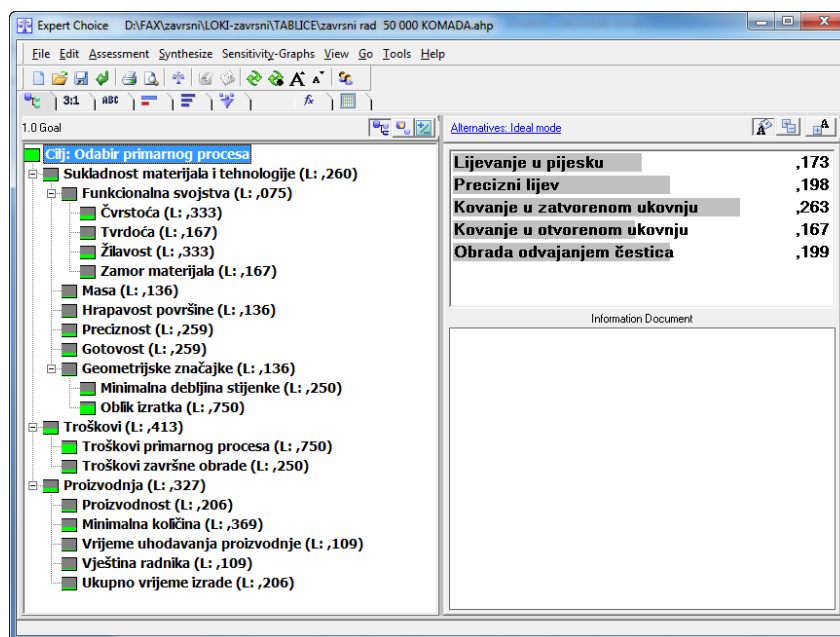


**Slika 7.25** Rezultati procjene alternativa u odnosu na podkriterij Ukupno vrijeme izrade  
Također sa slika je vidljivo i iznos nekonzistentnosti, koja ne prelazi 4%. Što ukazuje na dosljednost donositelja odluke.

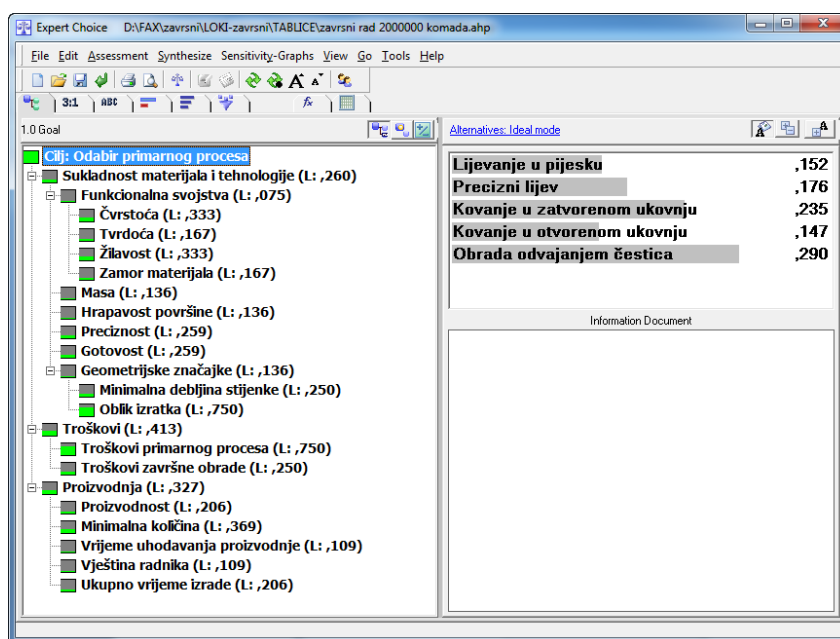


## 7.4. Rezultati AHP metode u Expert Choice-u

Nakon dodjeljivanja prioriteta alternativama i težina kriterijima i podkriterijima, dobiveni su rezultati postavljenog problema odlučivanja (Slika 7.26) (Slika 7.27). Iz sinteze rezultata prema idealnom načinu vidljivo je da je za veličinu serije 50 000 komada alternativa *Kovanje u zatvorenom ukovnju* procijenjena kao optimalno rješenje problema, dok za veličinu serije od 2 000 komada *Obrada odvajanjem čestica*.



Slika 7.26 Model View prikaz rezultata za veličinu serije 50 000 komada



Slika 7.27 Model View prikaz rezultata za veličinu serije 2 000 komada

### 7.4.1. Konzistentnost

Kao što je već rečeno ako je *CR manji od 0.10 rezultat je dovoljno točan* i nema potrebe za korekcijama u uspoređenjima i ponavljanja proračuna. Ako je CR veći od 0.10, rezultate bi trebalo ponovo analizirati i ustanoviti razloge nekonzistentnosti i ukloniti ih djelomičnim ponavljanjem uspoređenja u parovima. Ako ponavljanje procedure u nekoliko koraka ne dovede do sniženja CR-a do tolerantnog limita 0.10, sve rezultate treba odbaciti i ponoviti cijeli postupak od početka.

Slika 7.28 prikazuje ukupnu nekonzistentnost u procesu odabira primarnog procesa za veličinu serije 50 000 i veličinu serije 2 000 komada. Ukupne nekonzistentnosti iznose 0.0373 i 0.0310, što u postocima iznosi 3.73 % i 3.10 %, što je ispod graničnih 10% te se rezultati smatraju dovoljno točnim i nema potrebe za korekcijama u uspoređenjima i ponavljanja proračuna. Pojedine parcijalne nekonzistentnosti mogu se vidjeti na svim slikama koje prikazuju sintezu rezultata usporedba kriterija, podkriterija i alternativa u ovome poglavlju.

Veličina serije 50 000 komada			
PID	Name	Overall	Troškovi primarnog procesa (L: .750)
		#Factors	5 Alts
0	Facilitator	.0373	.0612

Veličina serije 2 000 komada			
PID	Name	Overall	Cilj: Odabir primarnog procesa
		#Factors	3
0	Facilitator	.0310	.0511


Slika 7.28 Nekonzistentnost odabira primarnog procesa

### 7.4.2. Graf osjetljivosti

U nastavku će biti prikazani dijagrami pomoću kojih se provodi analiza osjetljivosti rezultata. Analizom osjetljivosti može se utvrditi kako će promjena težina pojedinih kriterija utjecati na promjenu vrijednosti prioriteta alternativa, te se pomoću dobivenih rezultata može izvršiti optimizacija konačnog rješenja postavljenog problema.


Na Slici 7.29 prikazan je dijagram osjetljivosti *Performance*. Ova opcija omogućuje prikaz utjecaja pojedinih težina kriterija na trenutni i ukupni poredak alternativa. Trenutni poredak alternativa predstavlja promjenu prioriteta alternativa pod utjecajem težine jednog kriterija, a ukupni poredak alternativa predstavlja poredak alternativa pod utjecajem težina svih kriterija. Iz slike je vidljivo da je prva alternativa za veličinu serije 50 000 komada *Kovanje u zatvorenom ukovnju*, dok je prva alternativa za veličinu serije 2 000 komada *Obrada odvajanjem čestica*, kako je prikazano na desnoj strani vertikalnih osi. Na lijevoj strani

vertikalne osi prikazane su težine pojedinih kriterija, dok su na horizontalnoj osi prikazani kriteriji i njihov utjecaj na pojedinu alternativu.



**Slika 7.29 Dijagram osjetljivosti Performance**

Na Slici 7.30 prikazan je dijagram osjetljivosti *Dynamic*. Primjenom ove opcije moguće je vidjeti kako se dinamički mijenjaju prioriteta alternativa ukoliko se jednostavnim povlačenjem miša u lijevu ili desnu stranu mijenjaju težine pojedinih kriterija. Na lijevoj strani slike prikazane su težine pojedinih kriterija u odnosu na cilj, dok su na desnoj strani prikazani prioriteta alternativa. Također je uključena opcija *Components*, te su vidljivi udjeli težina pojedinih kriterija u svakoj od alternativa.



Slika 7.30 Dijagram osjetljivosti Dynamic

### 7.5. Konačni odabir

Iz sinteze rezultata sa Slike 7.26 i Slike 7.27 vidljivo je da prioritet ima alternativa *Kovanje u zatvorenom ukovnju* za veličinu serije 50 000 komada, a za veličinu serije 2 000 komada *Obrada odvajanjem čestica*.

Kako veličina serije od 50 000 komada ide prema masovnoj proizvodnji te se zahtjeva visoka proizvodnost tehnologije, može se zaključiti da odabir alternative *Kovanje u zatvorenom ukovnju* ima smisla, jer tehnologija ima najvišu proizvodnost uz najkraća vremena izrade te se kao takva uzima za konačni odabir te serije.

Veličina serije od 2 000 komada za jednostavan izradak kao što je *Glavina* zahtijeva odabir tehnologije koja će biti ekonomična. Većini tehnologija, kao što su precizno lijevanje i kovanje u zatvorenom ukovnju troškovi rada padaju s količinom proizvoda, a kako je ovdje

---

„samo“ 2 000 komada isplativije je uzeti OOČ. Te se rezultat dobiven analizom kriterija, podkriterija i alternativa za veličinu serije od 2 000 komada uzima kao konačni.

No, iako su dobiveni rezultati očekivani, bitno je još jednom napomenuti da prilikom rješavanja ovog problema (Odabira primarnog procesa) veliki utjecaj je imala subjektivnost, neiskustvo i intuicija donositelja odluke, te nedostatak potrebnih podataka za ozbiljniju procjenu odabira primarnog procesa te je upitno da li bi se dobili isti rezultati.

## 8. MOGUĆNOST PRIMJENE AHP METODE U INDUSTRIJI

Postavlja se pitanje da li postoji mogućnost primjene AHP metode u industriji. Potrebno je sagledati „širu sliku“ prilikom odabira primarnog procesa, te se zapitati da li ima smisla tako široko razmatrati primarne procese.

Prilikom korištenja Expert Choice-a kao softvera za primjeru AHP metode u procesu odabira primarnog procesa potrebno je poznavanje ekspertnih znanja pojedinih tehnologija. Drugim riječima, potrebno je imati tim stručnjaka koji posjeduju ekspertna znanja pojedinih tehnologija i koji su spremni na timski rad (tzv. „*brainstorming*“), te nužnost strateškog promišljanja kod izrade novog pogona ili tvornice kod kojih bi imalo smisla tako široko razmatrati primarni proces.

Također je važno naglasiti da realne cijene alata, postupaka (lijevanje, deformiranje) su uvjetovane i zaposlenošću istih tvornica, njihovom fleksibilnošću proizvodnje, dosadašnjim odnosom kupac-dobavljač, situacijom na tržištu, utjecajem cijena kineskih kompanija i sl.

## ZAKLJUČAK

Zadatak ovog rada bio je objašnjenje korištenja AHP metode kod odabira primarnog procesa za konkretan izradak za dvije različite veličine serija koristeći tehnološke, organizacijske i ekonomske kriterije. Provedba AHP metode vršila se za konkretan izradak Glavinu, čiji je radionički crtež dan u Prilogu I, pomoću softvera Expert Choice 11.

Na temelju unesenih kriterija, podkriterija i alternativa u softver Expert Choice 11 dobiveni su rezultati, koji pokazuju da je najbolja alternativa, kod odabira primarnog procesa, za veličinu serije 50 000 komada *Kovanje u zatvorenom ukovnju*. Taj izbor je logičan pošto se s tom vrstom kovanja mogu postići željena strukturna i funkcionalna svojstva uz dovoljno visoku produktivnost. Zbog visoke količine proizvoda i ekonomski je isplativa tehnologija.

Rezultati dobiveni za veličinu serije od 2 000 komada predlažu kao optimalnu alternativu *Obradu odvajanjem čestica*. Rezultat je dovoljno pouzdan pošto se radi o maloj količini proizvoda, male mase i nekompleksnosti.

U konačnici može se zaključiti da upotreba Expert Choice-a kao alata za pomoć pri odabiru primarnog procesa je dobra ukoliko se dovoljno dobro poznaje problem, ako se posjeduju precizni podaci o tehnologijama, ako donositelji odluka posjeduju potrebna ekspertna znanja i iskustva te je poželjno grupno odlučivanje jer se time smanjuje subjektivnost donositelja odluke.

## LITERATURA

- [1] Mrkus D., Završni rad, „Prikaz i analiza načina, vremena i troškova izrade odabranih pozicija alata za izradu staklene ambalaže“, FSB, Zagreb, 2008.
- [2] K.G.Swift., J.D.Booker, „Process Selection: From design to manufacture“, Butterworth-Heinemann, Oxford, 2003.
- [3] Lenac D., Diplomski rad (Predbolonja), „Razrada tehnološkog procesa izrade viličaste osovinice“, TVZ, Zagreb, 2005.
- [4] Ćosić P, „Odabir primarnog procesa“, Projektiranje tehnološkog procesa, FSB, Zagreb, 2014., predavanja.
- [5] Skladištenje,  
<http://www.skladistenje.com/poslovno-odlucivanje-i-sustavi-za-potporu-odlucivanju/>
- [6] Imamagić E., Seminarski rad, „Sustavi za potporu odlučivanju“, FER, Zagreb, 2010.
- [7] Power D.J., „A Brief History of Decision Support Systems“,  
<http://dssresources.com/history/dsshistory.html>
- [8] Power D.J., „Decision Support Basics“, Business Expert Press, New York, 2009.
- [9] Nestić S., Stefanović M., „Komponente i klasifikacija DSS-Koncepti WEB baziranih DSS sistema“,  
<http://www.cqm.rs/2011/FQ2011/pdf/38/41.pdf>
- [10] HO CIRED, „Primjena analitičkog hijerarhijskog procesa u određivanju prioriteta investicijskih ulaganja uz pomoć programskog paketa Expert Choice“,  
<http://www.ho-cired.hr/referati/SO5-05.pdf>
- [11] Scribd,  
<https://www.scribd.com/doc/132880990/Ahp>
- [12] Cerovšek K., Diplomski rad, „Odabir alatnih strojeva u projektiranju tehnoloških procesa“, FSB, Zagreb, 2014.
- [13] Karleuša B., Deluka-Tibljaš A., Benigar M., „Mogućnosti primjene postupaka višekriterijske optimizacije u prometnom planiranju i projektiranju“,  
[http://www.veleri.hr/files/datoteke/nastavni\\_materijali/k\\_promet\\_s1/Visekriterijska-optimizacija-clanak.pdf](http://www.veleri.hr/files/datoteke/nastavni_materijali/k_promet_s1/Visekriterijska-optimizacija-clanak.pdf)




- [14] Aleksi I., Hocenski Ž., Elaborat, „Primjena Expert Choice alata i AHP metode za odabir Virtex-5 FPGA čipa“, Elektrotehnički fakultet u Osijeku, Osijek, 2009.
- [15] The Analytic Hierarchy Process,  
[http://www.springer.com/cda/content/document/cda\\_downloadaddocument/9781852337568-c1.pdf?SGWID=0-0-45-110278-p7221558](http://www.springer.com/cda/content/document/cda_downloadaddocument/9781852337568-c1.pdf?SGWID=0-0-45-110278-p7221558)
- [16] Wikipedia,  
[http://en.wikipedia.org/wiki/Analytic\\_hierarchy\\_process](http://en.wikipedia.org/wiki/Analytic_hierarchy_process)
- [17] Lisjak D., „Izbor opreme AHP metodom“, Održavanje, FSB, Zagreb, 2014., predavanja.
- [18] Analitički hijerarhijski proces (ahp),  
<http://bsrdjevic.tripod.com/download/5.pdf>
- [19] Analytic hierarchy process,  
[http://www.ivm.vu.nl/en/Images/MCA3\\_tcm53-161529.pdf](http://www.ivm.vu.nl/en/Images/MCA3_tcm53-161529.pdf)
- [20] The Analytic Hierarchy Process and Expert Choice,  
<http://professorforman.com/decisionbyobjectives/chapter4.pdf>
- [21] Expert Choice,  
<http://expertchoice.com>
- [22] Bruhn Barfod M., „Graphical and technical options in Expert Choice for group decision making“,  
[http://orbit.dtu.dk/files/104238680/DTU\\_Transport\\_Compendium\\_Part\\_3\\_Group\\_decision\\_making\\_.pdf](http://orbit.dtu.dk/files/104238680/DTU_Transport_Compendium_Part_3_Group_decision_making_.pdf)
- [23] Briš Alić M., „Primjena AHP metode i Expert Choice softvera u procesu donošenja odluke“, Ekonomski fakultet u Osijeku, Osijek, 2013.  
[http://www.efos.unios.hr/arhiva/index.php/component/docman/doc\\_download/7983-menadzersko-odlucivanje-27052013](http://www.efos.unios.hr/arhiva/index.php/component/docman/doc_download/7983-menadzersko-odlucivanje-27052013).
- [24] Filetin T., Matijević B., Marić G., Unkić F., „Tehnologičnost, podjela tehnologija materijala, izbor i troškovi tehnologija“, Napredne tehnologije materijala, Metalurški fakultet, Sisak, 2011., predavanja.

## **PRILOZI**

- I. Radionički crtež - Glavina
- II. Sukladnost materijala i tehnologije [4]
- III. Opće značajke ljevačkih postupaka [4]
- IV. Opće značajke postupaka deformiranja [4]
- V. Postupci proizvodnje i njihovi atributi [24]

## Prilog I. Radionički crtež – Glavina



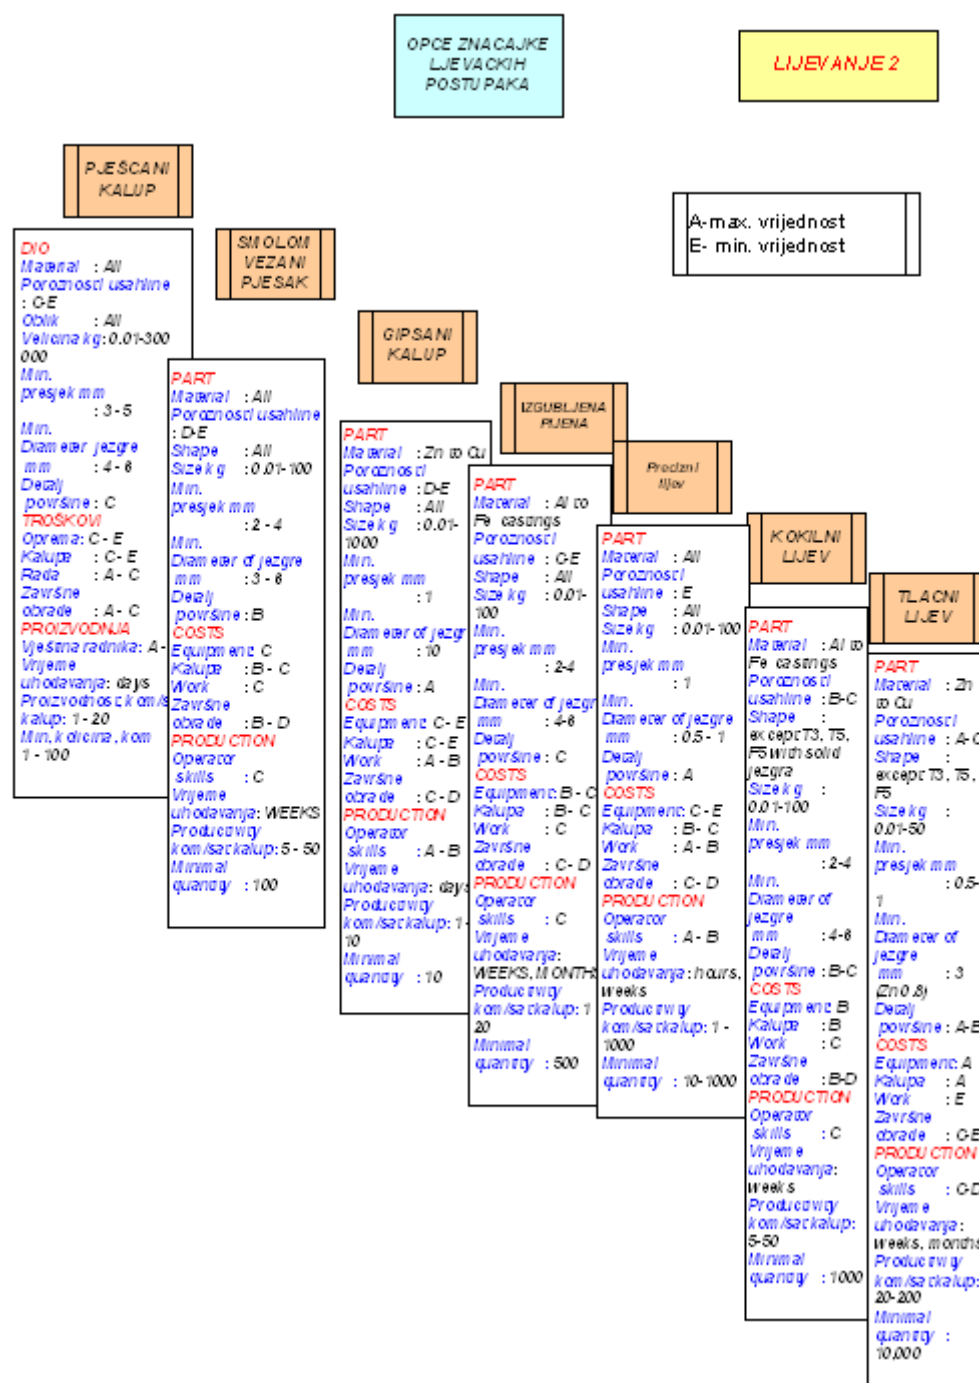
## Prilog II. Sukladnost materijala i tehnologije [4]

Tehnologija/ postupak	Svi i NL lijev	Negirani čelik	Legirani čelik	Nehrđajući čelik	Al i Al legure	Cu i Cu legure	Zn i Zn legure	Mg i Mg legure	Ti i Ti legure	Ni i Ni legure	Vatrostalni metali	Plastomeri	Dakromeri
<b>Lijevanje i srodni postupci</b>													
Lijevanje u pijesku	+	+	+	+	+	+	-	+	-	+	-	X	X
Precizno lijevanje	-	+	+	+	+	+	-	-	-	+	-	X	X
Tlačno lijevanje	X	X	X	X	+	-	+	+	X	X	X	X	X
Injekcijsko prešanje	X	X	X	X	X	X	X	X	X	X	X	+	-
Prešanje pjene	X	X	X	X	X	X	X	X	X	X	X	+	X
Ekstruzijsko puhanje	X	X	X	X	X	X	X	X	X	X	X	+	X
Injekcijsko puhanje	X	X	X	X	X	X	X	X	X	X	X	+	X
Rotacijsko kalupljenje	X	X	X	X	X	X	X	X	X	X	X	+	X
<b>Kovanje i prešanje</b>													
Istiskivanje	X	+	+	-	+	+	+	-	X	X	X	X	X
Hladno sabijanje	X	+	+	+	+	+	-	-	X	-	X	X	X
Kovanje u zatvorenom ukovnju	X	+	+	+	+	+	X	+	+	-	-	X	X
Prešanje i sinteriranje	X	+	+	+	+	+	X	+	-	+	+	X	X
Topla ekstruzija	X	+	-	-	+	+	X	+	-	-	-	X	X
Rotacijsko kovanje	X	+	+	+	+	-	-	+	X	+	+	X	X
<b>Obrada odvajanjem čestica</b>													
Obrada iz sirovca	+	+	+	+	+	+	+	+	-	-	-	-	-
Elektrokemijska obrada	+	+	+	+	-	-	-	-	+	+	-	X	X
Elektroerozija (EDM)	X	+	+	+	+	+	-	-	-	+	-	X	X
EDM sa žicom	X	+	+	+	+	+	-	-	-	+	-	+	X
<b>Oblikovanje deformiranjem</b>													
Oblikovanje lima	X	+	+	+	+	+	-	-	-	-	X	X	X
Toplo oblikovanje	X	X	X	X	X	X	X	X	X	X	X	+	X
Optiskivanje	X	+	-	+	+	+	+	-	-	-	-	X	X

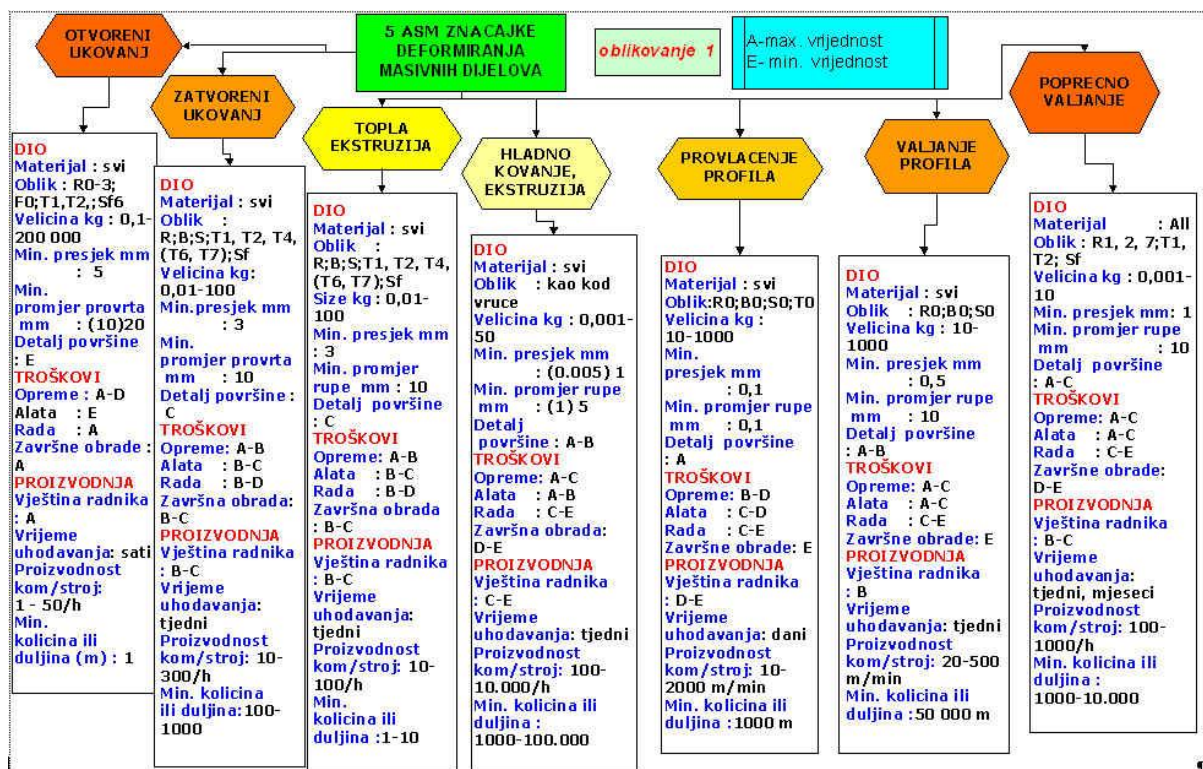
Tablica 5.1 - Sukladnost materijala i postupaka proizvodnje, ASM - **NAJBOLJI IZBOR : +, tek potom -**[3]

+ normalna praksa, - manje prihvatljivo, x neprihvatljivo

## Prilog III. Opće značajke ljevačkih postupaka [4]



## Prilog IV. Opće značajke postupaka deformiranja [4]



Slika 3.8. ASM-značajke deformiranja masivnih dijelova

## Prilog V. Postupci proizvodnje i njihovi atributi [24]

**POSTUPCI PROIZVODNJE I NJIHOVI ATRIBUTI**

Postupak	HR	TD	KO	KT	KP	OB	TR
Tlačno lijevanje	N	V	V	V/S	V	S/N	V
Centrifugalno lijevanje	S	S	S	N	S/N	V/S/N	V/S
Izravno prešanje	N	V	S	V/S	V/S	V/S/N	V/S
Injekcijsko prešanje	N	V	V	V/S	V/S	S/N	V/S/N
Lijevanje u pijesku	V	S	S	N	V/S/N	V/S/N	V/S/N
Precizno lijevanje	N	V	V	N	V/S/N	S/N	V/S
Glodanje	N	V	V	S/N	V/S/N	V/S/N	V/S/N
Brušenje	N	V	S	N	S/N	S/N	V/S
Elektroerozija	N	V	V	N	N	S/N	V
Puhanje	S	S	S	V/S	V/S	S/N	V/S/N
Kovanje	S	S	S	V/S	V/S	V/S/N	V/S
Valjanje	N	S	V	V	V	V/S	V/S
Ekstruzija	N	V	V	V/S	V/S	S/N	V/S
Metalurgija praha	N	V	V	V/S	V	N	V/S
<b>Ključ ocjena:</b>							
V – visoko	> 6,3	< 0,13	visoka	> 100	> 5000	> 0,5	
S – srednje	1,6...6,3	0,13...1,3	srednja	10...100	100...5000	0,02...0,5	
N – nisko	< 1,6	> 1,3	niska	> 10	< 100	< 0,02	
Jedinice	μm	mm		kom/sat	komada	m <sup>2</sup>	

**Oznake atributa postupaka:**

HR – hrapavost; TD – točnost dimenzija; KO – kompleksnost oblika; KT – proizvedena količina u jedinici vremena; KP – ukupna količina proizvodnje; OB – oblik (projicirana ploština); TR – relativni trošak